

Pau Úbeda Puyo

**DETERMINANTES DE LOS RENDIMIENTOS DEL ORO: UN ENFOQUE DE
COMPONENTES PRINCIPALES ANTE EL CAMBIO ESTRUCTURAL DEL
COVID-19**

TRABAJO DE FIN DE GRADO

Grado de Economía



**FACULTAT D'ECONOMIA i EMPRESA
Universitat Rovira i Virgili**

Reus

Curso 2025-26

Índice

Título resumen y palabras clave	4
1. Presentación	5
2. Introducción	6
3. Marco teórico	8
4. Metodología	9
4.1. Análisis de componentes principales	10
4.1.1. Requisitos previos	10
4.1.2. Identificación de los componentes principales	11
4.1.3. Resolución del problema	12
4.2. Extracción del número óptimo de componentes	16
4.3. Regresión lineal por mínimos cuadrados ordinarios	17
5. Datos	19
5.1. Temporalidad del dataset	20
5.2. Transformaciones de las variables	20
6. Resultados	21
6.1. PCA pre-COVID	22
6.2. PCA post-COVID	26
6.3. PCA con variables crypto	29
6.4. Regresión lineal de los componentes sobre los rendimientos del oro	34
7. Conclusiones	36
7.1. Conclusiones generales	38
8. Bibliografía	41

9. Anexos	42
Anexo I. Tabla de variables	42

1. Título resumen y palabras clave

DETERMINANTES DE LOS RENDIMIENTOS DEL ORO: UN ENFOQUE DE COMPONENTES PRINCIPALES ANTE EL CAMBIO ESTRUCTURAL DEL COVID-19.

Aquest treball de final de grau investiga els determinants dels rendiments de l'or i analitza l'existència d'un trencament estructural derivat de la pandèmia de la COVID-19. L'estudi parteix de la premissa que els actius financers responen a forces sistèmiques comunes o comoviments i avalua si les dinàmiques tradicionals d'aquest actiu refugi han estat alterades per la inestabilitat global recent i la irrupció dels criptoactius.(Català)

Este trabajo de fin de grado investiga los determinantes de los rendimientos del oro y analiza la existencia de un quiebre estructural derivado de la pandemia del COVID-19. El estudio parte de la premisa de que los activos financieros responden a fuerzas sistémicas comunes o comovimientos y evalúa si las dinámicas tradicionales de este activo refugio han sido alteradas por la reciente inestabilidad global y la irrupción de los criptoactivos.(Castellano)

This bachelor's thesis investigates the determinants of gold returns and analyzes the existence of a structural break derived from the COVID-19 pandemic. The study is based on the premise that financial assets respond to common systemic forces or co-movements and evaluates whether the traditional dynamics of this safe-haven asset have been altered by recent global instability and the emergence of crypto assets.(Inglés)

1. Presentación

Mi principal motivación al escoger este tema para el Trabajo fue el hecho de poder unir una de las partes de la carrera que más me han gustado con uno de los temas actuales de controversia como es el oro, que es lo que hace que su precio varíe y cómo podríamos cuantificar esa variación, si se pudiese cuantificar.

A mi modo de ver el hecho de que sea un tema de actualidad (especialmente con la irrupción de las criptomonedas y los cambios tras la pandemia) me genera la necesidad de poder entender, usando la econometría que es lo que está pasando. En un entorno donde todo el mundo puede tener acceso inmediato a datos y noticias instantáneas aún veo más importante el hecho de profundizar en el tema y poder cuantificar que pasa realmente.

Finalmente, para poder desarrollar este trabajo me he apoyado básicamente en dos asignaturas: la econometría que me permite analizar de forma analítica, limpiar y transformar los datos para poder llevar a cabo la interpretación de los mismos usando el análisis de datos macroeconómicos, este punto es el que nos conecta con la realidad después de la parte más numérica transformamos estos números en conclusiones.

Este trabajo de fin de grado es mi forma de unir y dar una utilidad a toda la parte lectiva de mi grado con lo que me causa curiosidad en la vida real.

2. Introducción

La economía actual se caracteriza por la fuerte interconexión de sus mercados, donde los activos financieros no fluctúan de manera aislada, sino que responden a fuerzas comunes denominadas “comovimientos” West y Wong (2013). Históricamente, el oro ha destacado dentro de esta dinámica como un barómetro clave de la estabilidad global, evolucionando de ser un simple bien físico a un activo financiero estratégico integrado en las carteras de inversión. Sin embargo, en los últimos años, acontecimientos como la irrupción de la pandemia del COVID-19 y la entrada de las criptomonedas han provocado cambios profundos en la economía.

Entender si estas transformaciones han alterado la estructura del mercado y el comportamiento del oro resulta de gran relevancia. A nivel teórico y práctico, nos permite comprobar si las reglas tradicionales que guían a los activos refugio siguen vigentes hoy en día o si, por el contrario, nos enfrentamos a un escenario económico totalmente distinto y más complejo. En un entorno donde tenemos acceso inmediato a noticias y datos, es necesario ir más allá del ruido diario y utilizar la econometría para cuantificar qué está pasando realmente. Por este motivo, el objetivo principal de este trabajo de fin de grado es intentar detectar si realmente existe ese quiebre estructural provocado por el COVID-19.

Para lograrlo, el estudio se centra en identificar, dentro de un amplio panel de variables, cuáles son las verdaderamente relevantes y cómo afectan a la estructura del mercado comparando un periodo pre-COVID y otro post-COVID. Asimismo, se plantea analizar si al introducir variables crypto en el modelo estas afectan de alguna forma a los resultados. Finalmente, el trabajo busca comprobar si esos componentes extraídos tienen alguna afectación real sobre los rendimientos del oro, tanto antes como después de la pandemia.

Para poder dar respuesta a estos objetivos y contrastar las hipótesis, la metodología empleada se sustenta básicamente en dos procedimientos estadísticos. En primer lugar, se utiliza el Análisis de Componentes Principales (PCA) para reducir los datos y descubrir las dimensiones latentes del mercado, utilizando los criterios de Bai y Ng para seleccionar el número óptimo de componentes. Posteriormente, se aplica una regresión lineal por mínimos cuadrados ordinarios (MCO) para observar el impacto de estos factores sobre los rendimientos mensuales del oro.

Finalmente, para facilitar su lectura, el TFG se estructura en los siguientes apartados. Tras esta introducción, el apartado 3 presenta el marco teórico que fundamenta la idea

de los “comovimientos” y el uso del análisis factorial. En el apartado 4 se desarrolla de forma analítica la metodología estadística a aplicar. El apartado 5 describe las variables seleccionadas, su temporalidad y las transformaciones realizadas. A continuación, el apartado 6 expone los resultados obtenidos al comparar el periodo pre-COVID, el periodo post-COVID y un modelo extra que incluye variables cripto. Por último, el apartado 7 recoge las conclusiones generales del trabajo.

3. Marco teórico

La premisa central de este trabajo nace de la observación de que los activos financieros no fluctúan de manera aislada, sino que responden a fuerzas sistémicas comunes denominadas "comovimientos" (co-movements). Siguiendo la evidencia presentada por West y Wong (2013), un panel de precios de materias primas tiende a estar dominado por unos pocos factores globales que capturan la varianza común. En este contexto, el oro destaca como uno de los activos con mayor sensibilidad a estas dinámicas sistémicas, actuando a menudo como un barómetro de la estabilidad global.

Esta idea se complementa con el concepto de financiarización de las materias primas. Como señalan Blocher, Cooper y Molyboga (2016), el oro ha evolucionado de ser un bien puramente físico a un activo financiero estratégico integrado en carteras globales. Su comportamiento actual no depende únicamente de la oferta y demanda física, sino que está estrechamente vinculado al sentimiento de riesgo global y a la liquidez del mercado. Esta realidad justifica el análisis del oro de forma conjunta con variables bursátiles, monetarias y de volatilidad en un modelo unificado de factores.

Ante la complejidad de gestionar un panel extenso de 27 variables macroeconómicas y financieras, la investigación se apoya en el análisis factorial como herramienta de síntesis. Siguiendo a Hair et al. (1999), el análisis factorial es una técnica de interdependencia cuyo propósito principal es definir la estructura subyacente entre las variables del análisis.

En este estudio, la aplicación del Análisis de Componentes Principales (PCA) responde a dos objetivos fundamentales descritos por Hair et al. (1999) en las páginas 80 y 81 de su obra:

- Reducción de datos: El proceso permite resumir la información contenida en las 27 variables originales en un conjunto mucho más pequeño de factores (componentes), minimizando la pérdida de información y facilitando la manejabilidad de los datos.
- Identificación de la estructura: El modelo ayuda a descubrir las dimensiones latentes que agrupan a variables con comportamientos similares, permitiendo

entender qué fuerzas económicas reales (como la liquidez, el riesgo o la inflación) están moviendo el sistema en su conjunto.

Desde una perspectiva metodológica, Hair et al. (1999) subrayan que el análisis factorial suele ser más "conceptual" que otras técnicas multivariantes, ya que se centra en la matriz de correlaciones como base de entrada para identificar estas relaciones. Además, los autores enfatizan que la selección de las variables incluidas en el modelo debe tener una base teórica previa, lo que justifica la integración de indicadores macroeconómicos, bursátiles y criptoactivos. Este enfoque permite extraer el "ruido" individual de cada serie y obtener una base sólida para cuantificar el impacto de los factores comunes sobre los rendimientos del activo refugio analizado.

Finalmente, se compararán los periodos de Enero del 2015 a Marzo del 2020, y del Abril del 2020 a Diciembre del 2025, básicamente queremos observar si el COVID-19 tiene algún efecto en la estructura de los factores, y a su vez en la relación de los factores extraídos posteriormente y su regresión sobre los rendimientos mensuales del oro de los mismos periodos.

4. Metodología

Todo este trabajo se sustenta básicamente en dos procedimientos estadísticos, el análisis de componentes principales, y la regresión lineal por mínimos cuadrados ordinarios. Puesto que estos dos métodos estadísticos que ya están desarrollados, la información para poder describirlos va a salir de dos fuentes básicamente.

El análisis de componentes principales se extrae del libro Hair et al.(capítulo 3), el paper de Quiróga y Villalobos(2015) y el documento Romero Béjar,2023. La regresión lineal por mínimos cuadrados ordinarios se extrae del libro Guevara y Uribe (2017) capítulo 1.

-Conocimientos previos

Antes de empezar con la metodología puramente técnica se van a explicar de forma sencilla estos 3 conceptos.

·Cargas Factoriales(factor loadings): “son las correlaciones entre cada variable y el factor. Las cargas indican el grado de correspondencia entre cada variable y el factor, haciendo una variable con mayor carga representativa del factor”. (Hair et al., 1999, p. 95).

·Autovalores(eigenvalues): según Hair et al., 1999, los autovalores son una medida de fuerza de un factor, nos dice cuánta información total es capaz de resumir un solo factor.

·Varianza idiosincrática (varianza única): según Hair et al., 1999, la varianza idiosincrática es aquella parte de la varianza de la variable que la hace única, que no comparte con ninguna variable.

4.1. Análisis de componentes principales

4.1.1. Requisitos previos

Para que el ACP produzca resultados válidos y significativos, es necesario que los datos cumplan tres condiciones antes de aplicar la técnica:

Variables correlacionadas. El ACP tiene sentido únicamente cuando existe correlación entre las variables originales, ya que su objetivo es precisamente aprovechar esa redundancia informativa para sintetizarla en un número menor de componentes. Por tanto, antes de aplicar el ACP conviene examinar la matriz de correlaciones y verificar que existen relaciones lineales significativas entre las variables.

Ausencia de outliers. El ACP es un método especialmente sensible a los valores extremos o atípicos. Dado que las componentes principales se obtienen maximizando la varianza, la presencia de un solo dato atípico puede distorsionar considerablemente la dirección de las componentes y, en consecuencia, alterar toda la interpretación del análisis.

Datos estandarizados. Las variables deben transformarse para que tengan media igual a 0 y desviación estándar igual a 1. Esta estandarización es necesaria porque el ACP trabaja con varianzas, y si las variables están medidas en escalas muy diferentes (por ejemplo, una en miles de euros y otra en porcentajes), aquellas con valores numéricamente más grandes dominarían la formación de las componentes, no por ser más informativas sino simplemente

por tener una escala mayor. Al estandarizar, todas las variables pasan a contribuir en igualdad de condiciones, y el análisis se realiza sobre la matriz de correlaciones en lugar de la de covarianzas, lo que garantiza resultados más equilibrados e interpretables.

4.1.2. Identificación de las componentes principales

Sea X_1, X_2, \dots, X_p un conjunto de p variables aleatorias correladas. Denotemos por

$$X = (X_1, X_2, \dots, X_p)^t$$

al vector aleatorio que forman. Asumimos que X es centrado,

$$E[X] = 0$$

y denotamos por

$$R = E[XX^t]$$

su matriz de covarianzas. Consideramos (no más de p) variables de la forma:

$$U_1 = a_1^t X, \dots, U_q = a_q^t X$$

el objetivo que se persigue es obtener los

$$a_1, \dots, a_q \in R^p, q \leq p$$

adecuados.

Requerimientos previos:

$$U_1 = a_1^t X, \dots, U_q = a_q^t X$$

Deben ser incorreladas. De esta forma se eliminará la información redundante.

La varianza de cada

$$U_i, i \in \{1, \dots, q\}$$

Es máxima. De esta forma las nuevas variables proporcionarán información significativa.

En las condiciones anteriores, el objetivo es encontrar

$$U_1 = a_1^t X, \dots, U_q = a_q^t X$$

Mutualmente incorreladas, teniendo cada U_i máxima varianza entre todas las combinaciones lineales de X incorreladas con

$$U_1 = a_1^t X, \dots, U_{i-1} = a_{i-1}^t X$$

Las variables

$$U_1 = a_1^t X, \dots, U_q = a_q^t X$$

Solución del problema anterior reciben el nombre de componentes principales.

4.1.3. Resolución del problema

Tal y como se ha indicado anteriormente, la resolución de este problema es secuencial:

- En primer lugar se obtiene U_1 imponiendo que tiene máxima varianza.
- A continuación se obtiene U_2 imponiendo que es la de mayor varianza entre todas las combinaciones lineales incorreladas(perpendiculares) a U_1 .
- Se procede del mismo modo para obtener U_3 imponiendo ahora que es la de mayor varianza entre todas las combinaciones lineales perpendiculares a U_1 y U_2 .
- Para el resto de componentes principales hasta U_q se procede del mismo modo.
- Resolución del problema(extracción de componentes)

A continuación, se va a justificar cómo los coeficientes de las componentes principales son los vectores propios de la matriz de covarianzas, asociados a los valores propios de mayor módulo en cada paso

En este primer paso se obtiene la primera componente principal U_1 maximizando su varianza. Para garantizar la existencia de este máximo han de imponerse condiciones de acotación sobre el vector de pesos, en este caso que a_1 es un vector unitario

$$Var [U_1]$$

$$s. a. ||a_1|| = a_1^t a_1 = 1$$

Teniendo en cuenta que X es un vector aleatorio centrado,

$$E[X] = 0$$

Se tiene que

$$E[a_1^t X] = 0$$

lo que implica que:

$$Var[U_1] = E[U_1^2] = E[a_1^t X a_1^t X] = E[a_1^t X X^t a_1] = a_1^t E[X X^t] a_1 = a_1^t R a_1$$

y por tanto el problema queda como sigue,

$$\max_{a_1} a_1^t R a_1$$

$$s. a. a_1^t a_1 = 1$$

Finalmente, aplicando el Teorema de los multiplicadores de Lagrange para la obtención de extremos condicionados, el problema se reduce a,

$$\max_{a_1} \{ a_1^t R a_1 - \lambda (a_1^t a_1 - 1) \}$$

Derivando la expresión anterior respecto a_1 (matricialmente y teniendo en cuenta que R es simétrica) e igualando a cero,

$$\frac{\partial (a_1^t R a_1 - \lambda (a_1^t a_1 - 1))}{\partial}$$

Se obtiene,

$$2R a_1 - 2\lambda a_1 = 0$$

a_1 es vector propio asociado a λ , valor propio de R , ya que la expresión anterior se escribe como,

$$(R - \lambda I) a_1 = 0$$

Que determina el subespacio propio asociado a λ . Finalmente, λ es la varianza de U_1 ya que,

$$Var[U_1] = a_1^t R a_1 = \lambda a_1^t a_1 = \lambda$$

Multiplicando (1) a la izquierda por a_1^t y porque a_1 es unitario.

En conclusión, la primera componente principal es

$$U_1 = a_1^t X$$

Con a_1 el vector propio asociado al valor propio de R con mayor módulo.

·Segundo paso (segunda componente principal)

En este segundo paso se obtiene la segunda componente principal, U_2 , incorrelada con la primera componente principal calculada anteriormente, maximizando su varianza.

Para garantizar la existencia de este máximo también han de imponerse condiciones de acotación sobre el vector de pesos, en este caso que a_2 es también un vector unitario.

$$\begin{aligned} &Var [U_2] \\ &s. a. \|a_2\| = a_2^t a_2 = 1 \\ &cov(U_1, U_2) = 0 \end{aligned}$$

Teniendo en cuenta que X es un vector aleatorio centrado,

$$E[X] = 0$$

Se tiene que

$$E[a_2^t X] = 0$$

lo que implica que, como antes:

$$Var[U_2] = a_2^t R a_2$$

Del mismo modo

$$cov(U_1, U_2) = E[a_1^t X a_2^t X] = E[a_1^t X X^t a_2] = a_1^t E[X X^t] a_2 = a_1^t R a_2$$

Y por tanto el problema queda como sigue,

$$\begin{aligned} &max_{a_2} a_2^t R a_2 \\ &s. a. a_2^t a_2 = 1 \\ &a_1^t R a_2 = 0 \end{aligned}$$

Finalmente, aplicando el Teorema de los multiplicadores de Lagrange para la obtención de extremos condicionados, el problema se reduce a,

$$max_{a_2} \{ a_2^t R a_2 - \lambda (a_2^t a_2 - 1) - \mu a_1^t R a_2 \}$$

Derivando la expresión anterior respecto a_1 (matricialmente y teniendo en cuenta que R es simétrica) e igualando a cero, se obtiene,

$$2Ra_2 - 2\lambda a_1 - \mu Ra_1 = 0$$

Si multiplicamos esta expresión a la izquierda por a_1^t se obtiene,

$$2a_1^t Ra_2 - 2\lambda a_1^t a_2 - \mu a_1^t Ra_1 = 0$$

Teniendo en cuenta que $a_1^t Ra_2 = 0$ (es la segunda restricción del problema), que $a_1^t a_2 = 0$ (son perpendiculares) y que $a_1^t Ra_1 \neq 0$, la expresión queda como $\mu a_1^t Ra_1 = 0$, de donde se deduce que $\mu = 0$.

Así que la ecuación a resolver es

$$2Ra_2 - 2\lambda a_2 = 0 \rightarrow (R - \lambda I)a_2 = 0$$

De donde nuevamente se deduce que a_2 es el vector propio asociado al valor propio de λ de la matriz R .

De la misma forma,

$$Var[U_2] = a_2^t Ra_2 = \lambda a_2^t a_2 = \lambda$$

Multiplicando la ecuación anterior a la izquierda por a_2^t y teniendo en cuenta que a_2 es unitario.

En conclusión, la segunda componente principal es

$$U_2 = a_2^t X$$

Siendo a_2 el vector propio asociado al segundo valor propio de mayor módulo de la matriz R

·Paso 3 y sucesivos

$$Var [U_3]$$

$$s. a. \|a_3\| = a_3^t a_3 = 1$$

$$cov(U_1, U_3) = 0$$

$$cov(U_2, U_3) = 0$$

Y seguiríamos con los mismos pasos de resolución anteriores.

A partir del paso 3, ya se hace de forma sucesiva con todos los números de factores, recordando siempre que el número de factores debe ser menor al número de variables, ya que este método es para reducir las dimensiones.

4.2. Elección del número óptimo de componentes

Para determinar el número de factores comunes en el presente análisis, se ha seguido la metodología propuesta por Bai y Ng (2002).

El modelo parte de la premisa de que las variaciones en un gran número de variables económicas pueden ser explicadas por un pequeño número de variables de referencia o factores. La representación matemática de los datos observados X_{it} es:

$$X_{it} = \lambda_i' F_t + e_{it}$$

Donde F_t representa el vector de factores comunes, λ_i es el vector de cargas (factor loadings) y e_{it} es el componente idiosincrásico. Para estimar el número de factores se define:

$$V(k, \hat{F}^k) = \frac{1}{NT} \sum_{i=1}^N \sum_{t=1}^T (X_{it} - \lambda_i^{k'} \hat{F}_t^k)^2$$

Esta función de pérdida cuantifica la varianza residual media para cada unidad de la muestra.

Debido a que $V(k)$ disminuye necesariamente a medida que se añaden factores, es preciso introducir una función de penalización $g(N, T)$ que dependa de ambas dimensiones del panel. Siguiendo el Teorema 2 y el corolario del paper por Bai y Ng (2002), se han considerado los criterios de información de panel (IC_p), definidos de la siguiente forma:

$$IC_{p1}(k) = V(k, \hat{F}^k) + k \left(\frac{N+T}{NT} \right) \ln \ln \left(\frac{NT}{N+T} \right)$$

$$IC_{p2}(k) = V(k, \hat{F}^k) + k \left(\frac{N+T}{NT} \right) \ln \ln (C_{NT}^2)$$

Donde

$$C_{NT}^2 = \{N, T\}$$

Estos criterios permiten una estimación consistente del número de factores, asegurando que la penalización por parsimonia se ajuste correctamente al tamaño de la muestra en ambas dimensiones.

El procedimiento de selección del número óptimo de componentes (\hat{k}) consiste en los siguientes pasos:

- Estandarización: previamente al cálculo los datos son centrados y estandarizados (como se ha explicado en el principio de la metodología).
- Definición de un límite superior: Se establece un número máximo de factores candidatos (k_{max}).
- Minimización del criterio: Se calcula el criterio elegido para cada valor de k desde 0 hasta k_{max} . El número óptimo de factores es aquel que minimiza la función:

$$\hat{k} = \arg IC_p(k)$$

4.3. Regresión lineal por mínimos cuadrados ordinarios

Finalmente, para terminar este trabajo se ha utilizado una regresión lineal por mínimos cuadrados ordinarios, a continuación se explica la parte matemática del método estadístico, extraído del documento Manjón Antolín, M. C.

Disponemos de una muestra de sección cruzada en la que N agentes económicos de naturaleza similar proporcionan información relativa a las variables

$$x = (x_1, x_2, x_3, \dots, x_k)$$

E y en un mismo momento temporal. Esto significa que para cada observación $i=1, 2, \dots, N$ tenemos la siguiente recta de regresión muestral:

$$y_i = x_i \hat{\beta} + e_i$$

Siendo $x_i = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{ik})$, $\hat{\beta}$ un estimador del parámetro β de dimensión $K \times 1$ y e_i el error muestral cometido al emplear un estimador en lugar del verdadero valor poblacional. Análogamente, si la muestra consiste en T observaciones temporales relativas a un único individuo la recta de regresión muestral vendría dado por

$$y_t = x_t \hat{\beta} + e_t$$

Con $t=1, 2, \dots, T$ y $x_t = (x_{t1}, x_{t2}, x_{t3}, \dots, x_{tk})$.

La relación población-muestra en el contexto de series temporales es menos intuitiva, pero por lo demás no existe ninguna diferencia fundamental entre ambas rectas de regresión.

En particular, el criterio seguido para la construcción del estimador MCO es la minimización de la suma de los errores muestrales al cuadrado. Matemáticamente:

$$\beta^{MCO} = \arg \sum_{i=1}^N (e_i)^2$$

Para resolver este problema de minimización, definamos la siguiente función objetivo:

$$\begin{aligned} SR(\hat{\beta}) &= \sum_{i=1}^N (e_i)^2 \\ &= \sum_{i=1}^N (y_i - x_i \hat{\beta})^2 \end{aligned}$$

A partir de la anterior expresión, en la que SR denota la “Suma de residuos” (o errores muestrales) de la regresión, es fácil deducir las siguientes condiciones de primer orden:

$$\frac{\partial SR(\hat{\beta})}{\partial \hat{\beta}} = -2 \sum_{i=1}^N x_i' (y_i - x_i \hat{\beta}) = -2 \sum_{i=1}^N x_i' y_i + 2 \sum_{i=1}^N x_i' x_i \hat{\beta}$$

Igualando estas condiciones a cero,

$$-2 \sum_{i=1}^N x_i' y_i + 2 \sum_{i=1}^N x_i' x_i \hat{\beta} = 0$$

Y reordenando el resultado,

$$\sum_{i=1}^N x_i' x_i \hat{\beta} = \sum_{i=1}^N x_i' y_i$$

Obtenemos las denominadas ecuaciones normales de la regresión. Este sistema con K parámetros desconocidos tiene una solución única si la matriz simétrica $\sum_{i=1}^N x_i' x_i$

no es singular (condición de identificación en este caso):

$$\hat{\beta} = \left(\sum_{i=1}^N x_i' x_i \right)^{-1} \sum_{i=1}^N x_i' y_i = \beta^{MCO}$$

Una vez definido el estimador MCO, se van a analizar sus principales propiedades en la siguiente tabla:

Hipotesis sobre	Supuestos	Expresion matemática asociada	Violaciones
1. La especificación:	1.1 Lineal.	$y = x\beta + \varepsilon$	- No linealidad.
	1.2 Correcta.		- Omision (Inclusion) variables (i)relevantes.
2. Los regresores:	2.1 Linealmente indep. con $N > K$.	$\sum_{j=1}^K \lambda_j x_j \neq 0$, x rango completo	- Multicolinealidad.
	2.2 Fijos (exógenos).	$E(\varepsilon \mathbf{x}) = 0$	- Endogeneidad.
3. Las perturbaciones:	3.1 Indep. regresores.	ε_i, x_i indep.	
	3.2 Esperanza nula.	$E(\varepsilon_i) = 0$	
	3.3 Varianza const.	$Var(\varepsilon_i) = \sigma^2$	- Heteroscedasticidad.
	3.4 No autocorrel.	$Cov(\varepsilon_i, \varepsilon_j) = 0$	- Autocorrelación.

Imagen 1: Hipótesis y valoraciones del Modelo de Regresión Lineal Estándar. Extraído del mismo documento mencionado anteriormente.

5. Datos

Como se ha expuesto anteriormente, la premisa de este estudio se fundamenta en la observación de que los activos financieros no fluctúan de manera aislada, sino que responden a fuerzas sistémicas comunes denominadas "comovimientos" (comovements). Basándose en la evidencia de West y Wong (2013), se asume que los paneles de precios de las materias primas están dominados por factores globales que capturan la varianza común, siendo el oro un barómetro clave de esta estabilidad. Esta idea se complementa con el concepto de financiarización de las materias primas desarrollado por Blocher, Cooper y Molyboga (2016).

No obstante, es importante subrayar que para este proyecto no se ha replicado el dataset de los autores citados, sino que se ha elaborado una base de datos propia y

actualizada que busca una visión general de los mercados de Estados Unidos y Europa sin sobrecargar el modelo.

El conjunto de datos diseñado se organiza en tres grandes dimensiones: financiera, socioeconómica y cripto. En el ámbito financiero se incluyen indicadores monetarios como la M1 y M2, diferenciales de tipos de interés (10Y-3M), tipos de cambio frente al dólar y los principales índices bursátiles y de materias primas, tales como el S&P 500, Nasdaq 100, Euro Stoxx 50, petróleo de Brent o el cobre.

El bloque socioeconómico aporta información sobre la economía real y la psicología del mercado mediante índices de producción industrial, tasas de desempleo, salarios medios y métricas de sentimiento como el índice de la Universidad de Michigan, el indicador de clima empresarial de la Eurozona o el índice de volatilidad VIX.

Por último, se incorpora una dimensión de activos digitales (Bitcoin, Ethereum, Solana, Binance Coin y XRP) para analizar su posible integración en estas fuerzas sistémicas. Debido a la reciente incursión en el mercado global de todas las variables criptos, en el estudio solo se ha integrado bitcoin debido a que es la criptomoneda más antigua, todas las otras variables cripto se han añadido en una pequeña estimación a parte para poder realizar correctamente el análisis de componentes sin tener que distorsionar el dataset.

Cabe precisar que el precio del oro no forma parte del dataset utilizado para la extracción de factores comunes, sino que se emplea exclusivamente como variable dependiente en la regresión lineal posterior.

5.1. Temporalidad del dataset

Todas las series presentan una frecuencia mensual y se ha dividido el data set en dos ventanas una ventana pre-COVID, que abarca desde Enero del 2015 a Marzo del 2020, y otra ventana post-COVID que Abril de 2020 a Diciembre de 2025. Se escogió este periodo ya que en marzo de 2020 fue cuando en España y parte de Europa, se empezaron a percibir las consecuencias, tanto económicas como sociales del COVID-19.

5.2. Transformaciones de las variables

En el caso de aquellas variables expresadas originalmente en porcentajes o índices de sentimiento específicos, se han mantenido en sus niveles originales.

Para todas las otras variables se ha realizado dos transformaciones secuenciales, primero se ha aplicado el logaritmo y posteriormente se han calculado las primeras diferencias del mismo¹.

Para conocer con exactitud la denominación técnica de cada serie, su fuente original, su URL de descarga, así como la unidad de medida y la transformación específica aplicada a cada una de ellas, véase el Anexo 1.

6. Resultados

Para poder organizar todo el apartado de los resultados de nuestros experimentos, vamos a dividir los resultados en dos: periodo pre-COVID y periodo post-COVID.

También se añadirá un apartado extra, que es la inclusión en el modelo de variables cripto en el periodo post-COVID. En este apartado se va a valorar si la inclusión de las variables cripto tiene algún efecto sobre las cargas(loadings) en el análisis de componentes principales.

Debido a que los nombres de las variables suelen ser largos, en toda la parte práctica las variables vendrán codificadas por un número ya que, si se desea, o es necesario pintar un gráfico, se podrá observar con mayor claridad donde se sitúa cada variable, sin provocar saturación en las tablas, gráficas... En la siguiente tabla tenemos la codificación de las variables en el periodo pre-COVID y post-COVID

Nº Variable	Nombre de la variable
1	Ingresos medios por hora (USA)
2	Franco Suizo/Dólar
3	Yuan Chino/Dólar
4	Índice de Precios al Consumidor (USA)
5	Índice de Precios al Consumidor menos alimentos y energía (USA)
6	Índice de precios de vivienda (USA)
7	Precio del cobre

¹Según Hair et al. (1999) la transformación mediante la primera diferencia del logaritmo permite obtener los rendimientos de las series, garantizando su estacionariedad y la comparabilidad entre activos de distintas escalas. Este procedimiento es fundamental para estabilizar la varianza y aproximar la normalidad de los datos.

8	Precio Bitcoin
9	Euro Stoxx50
10	MSCI Emerging Markets
11	Nasdaq 100
12	S&P 500
13	Precio Gas natural
15	Precio Petróleo Brent
16	Euro/Dólar
17	Indicador de clima empresarial (Europa)
18	Libra Esterlina/Dólar
19	Índice de Precios al Consumidor menos alimentos y energía (Europa)
20	Índice de Precios al Consumidor (Europa)
21	Yen Japonés/Dólar
22	Masa monetaria M1 (USA)
23	Masa monetaria M2 (USA)
24	Diferencial entre el bono a 10años y el de 3 meses (USA)
25	Tasa desempleo (Europa)
26	Sentimiento del consumidor (USA)
27	Índice de volatilidad
28	Producción industrial (USA)
29	Producción industrial (Europa)

Tabla 1: Codificación de las variables utilizadas en la estimación PCA. Fuente: elaboración propia.

6.1. PCA pre-COVID

Una vez explicada la codificación de las variables, los periodos de tiempo utilizados en cada ventana, se adjunta el resultado de este PCA pre-COVID.

Dimensión	Varianza	% de Varianza	% Acumulado
Dim.1	6,848	24,457%	24,457%
Dim.2	3,157	11,275%	35,731%

Dim.3	2,413	8,618%	44,349%
Dim.4	2,258	8,065%	52,414%
Dim.5	1,596	5,699%	58,113%
Dim.6	1,347	4,810%	62,923%
Dim.7	1,189	4,247%	67,171%
Dim.8	1,061	3,789%	70,960%
Dim.9	1,041	3,720%	74,679%
Dim.10	0,931	3,325%	78,004%

Tabla 2. Resultado PCA pre-COVID en R-studio. Fuente:Elaboración propia.

Este es el resultado que nos aparece en la consola de R-studio, antes de tomar cualquier tipo de conclusión se va a proceder a ejecutar el criterio de Bai and Ng para saber cuántos componentes son los óptimos.

Criterio	Número óptimo de factores
IC1	4
IC2	1
IC3	10

Tabla 3. Criterio de Bai and Ng en R-studio pre-COVID. Fuente:elaboración propia.

Observamos que para este punto, y como se explica en la metodología, el número óptimo de factores es: 1 factor, es decir, el primer factor, una vez obtenido el número óptimo de factores, es interesante mostrar las cargas factoriales que tienen las variables sobre ese factor.

Número de variable	Dim.1
1	-0,374616
2	0,044463
3	0,450935
4	0,557016
5	0,492350

6	-0,097508
7	0,485245
8	0,260430
9	0,766546
10	0,788391
11	0,710914
12	0,849478
13	0,125293
15	0,803232
16	0,134800
17	0,288478
18	0,467001
19	-0,182612
20	0,170167
21	-0,142208
22	-0,505978
23	-0,730155
24	0,084145
25	0,104440
26	0,179648
27	-0,806391
28	0,482779
29	0,644177

Tabla 4. Cargas factoriales de las variables pre-COVID en R-studio. Fuente: elaboración propia.

Tras realizar el Análisis de Componentes Principales para el periodo pre-COVID, los resultados arrojan que el primer componente es el factor dominante, explicando el 24,457% de la varianza total de la muestra.

Al observar las cargas positivas, queda patente que los mercados bursátiles y la actividad económica real avanzaban en estrecha sintonía. Los indicadores que lideran

esta tendencia son el S&P 500 (Nº 12; 0,8494) y el Nasdaq 100 (Nº 11; 0,7109), lo que sugiere que el sector corporativo y tecnológico estadounidense era el principal motor de este factor. No obstante, esta fortaleza era compartida a nivel europeo, ya que el Euro Stoxx 50 (Nº 9; 0,7665) muestra un comportamiento casi idéntico. Esto confirma que, en este ciclo, los mercados de ambos continentes estaban profundamente integrados.

Es fundamental destacar que este avance no era puramente financiero. La fuerte presencia del Petróleo Brent (Nº 15; 0,8032), el Cobre (Nº 7; 0,4852) y los datos de Producción Industrial tanto en Europa (Nº 29; 0,6441) como en EE. UU. (Nº 28; 0,4827) otorgan una base tangible al análisis. El ascenso de este factor coincide con momentos en los que la industria funcionaba a pleno rendimiento. Incluso el IPC de EE. UU. (Nº 4; 0,5570) acompaña este movimiento, reflejando una inflación moderada propia de un ciclo económico expansivo y saludable.

En el extremo opuesto, encontramos las variables con cargas negativas, que actúan como indicadores de tensión. El caso más evidente es el VIX² (Nº 27; -0,8063), conocido como el "índice del miedo". Su signo negativo es totalmente coherente: cuando la confianza económica y las bolsas suben, la incertidumbre y la volatilidad en el mercado disminuyen de forma proporcional.

Tanto la M2 (Nº 23; -0,7301) como la M1 (Nº 22; -0,5059) presentan una relación inversa con el componente. Esto podría indicar que, en el periodo pre-COVID, la economía gozaba de una inercia propia; el crecimiento no dependía de estímulos monetarios extraordinarios ni de una creación masiva de liquidez por parte de los bancos centrales.

Por último, existen activos que en este análisis muestran una relevancia marginal o residual. El Bitcoin (Nº 8; 0,2604), aunque ya presentaba cierta inclinación hacia el mercado de riesgo, aún no formaba parte del núcleo de variables que definían el sentimiento global. Del mismo modo, el tipo de cambio Euro/Dólar (Nº 16) o la Tasa de desempleo en Europa (Nº 25) presentan cargas cercanas a cero, lo que sugiere que sus movimientos respondían a dinámicas internas o políticas específicas.

Teniendo en cuenta que este componente aumenta cuando la industria y las bolsas de Europa y Estados Unidos prosperan, y disminuye cuando aparece el pánico financiero,

² El VIX (CBOE Volatility Index) se le conoce popularmente como el "índice del miedo", y su función principal es medir qué tanta turbulencia esperan los inversores en el mercado de acciones de Estados Unidos durante los próximos 30 días.

podemos definirlo de manera sencilla como: La confianza y crecimiento real Europa-USA.

6.2. PCA post-COVID

Siguiendo la metodología aplicada anteriormente, se exponen seguidamente los resultados del PCA post-COVID

Dimensión	Varianza	% de Varianza	% Acumulado
Dim.1	7,018	25,064	25,064
Dim.2	4,122	14,723	39,787
Dim.3	3,020	10,787	50,574
Dim.4	2,278	8,134	58,708
Dim.5	1,666	5,949	64,657
Dim.6	1,399	4,995	69,652
Dim.7	1,211	4,324	73,976
Dim.8	1,079	3,854	77,830
Dim.9	0,948	3,386	81,216
Dim.10	0,770	2,750	83,966

Tabla 5. Resultado PCA post-COVID en R-studio. Fuente:Elaboración propia.

Seguidamente se ejecuta el mismo criterio para la elección del número de factores.

Criterio	Número óptimo de factores
IC1	10
IC2	4
IC3	10

Tabla 6. Criterio de Bai and Ng en R-studio post-COVID. Fuente:elaboración propia.

Observamos que para el periodo post-COVID, el criterio de Bai and Ng arroja resultados distintos al periodo previo. En este escenario, el indicador IC2 sitúa el número óptimo en 4 factores.

N° variable	Dim.1	Dim.2	Dim.3	Dim.4
1	-0,37715037	-0,6338331	0,319999122	-0,29355537
2	0,60744196	-0,48366935	-0,000110408	0,47914604
3	0,63033218	-0,35172325	0,148200968	0,33802796
4	-0,35729155	0,05128582	0,681121923	0,29015199
5	-0,4132707	-0,18654737	0,551528859	0,21204984
6	-0,15594062	0,25491988	0,662354301	0,13060654
7	0,60555121	-0,0781161	0,236484188	0,10635404
8	0,4278502	0,01980176	0,077591243	-0,44563023
9	0,60201019	-0,07370822	0,323934242	-0,39509904
10	0,81016059	-0,20928305	0,121087987	-0,01211875
11	0,70145804	-0,08697437	0,248376528	-0,42645216
12	0,72109638	-0,12661275	0,345654309	-0,44342939
13	-0,09073926	0,13081108	0,128624476	-0,30400054
15	0,27560036	0,51982942	0,36366362	-0,09475929
16	0,71996107	-0,39745332	0,009401906	0,42716305
17	-0,59731626	-0,2860511	0,590402634	0,07230514
18	0,71767061	-0,48446206	0,170458423	0,16946031
19	-0,41645936	-0,07296867	-0,063870636	0,2429555
20	-0,51634039	-0,14345685	0,065051041	0,05819635
21	0,56536044	-0,4403322	-0,059727739	0,33268287
22	0,3006968	0,68928973	-0,137219569	0,10770517
23	0,37506105	0,74201561	0,182934716	0,13806411
24	-0,23596111	0,31026658	0,646435727	0,3287775
25	0,47344449	0,38872932	-0,28956541	0,20485023
26	0,14925177	0,39880591	0,433836387	-0,12144225
27	-0,40343916	-0,11150578	-0,162309761	0,35037823
28	0,37928095	0,4298984	0,116807305	0,29752649
29	0,36364883	0,75513253	-0,075826028	0,24315902

Tabla 7. Cargas factoriales de las variables post-COVID en R-studio. Fuente: elaboración propia.

Tras la aplicación del Análisis de Componentes Principales (PCA) para el periodo post-COVID, los resultados revelan una estructura económica significativamente más compleja y fragmentada que en la etapa previa. Mientras que antes de la pandemia el mercado se movía bajo una sola dirección clara (un único factor de confianza), el escenario actual requiere de cuatro factores para ser explicado con precisión. Estos cuatro componentes explican, de manera conjunta, el 58,708% de la varianza total.

·Este primer componente explica el 25,064% de la varianza. Aunque mantiene la esencia del ciclo de crecimiento que vimos en el periodo pre-COVID, su composición interna ha cambiado.

Variables con carga positiva: Se observa una alta densidad de carga en los índices de renta variable y divisas vinculadas al riesgo: MSCI Emerging Markets (Nº 10; 0,8101), S&P 500 (Nº 12; 0,7210) y Nasdaq 100 (Nº 11; 0,7014). Es relevante el coeficiente de Bitcoin (Nº 8; 0,4278). Las divisas Euro (Nº 16; 0,7199) y Libra (Nº 18; 0,7176) mantienen su comportamiento procíclico.

Variables con carga negativa: Aparece una diferencia clave con el pasado; el factor se contrapone al Indicador de clima empresarial en Europa (Nº 17; -0,5973) y al IPC de Europa (Nº 20; -0,5163). Comparando con el pre-COVID, donde la inflación era señal de crecimiento sano, ahora se podría percibir como una amenaza de subida de tipos que genera inestabilidad en la bolsa. El VIX (Nº 27; -0,4034) sigue siendo negativo, confirmando que cuando el optimismo sube, el miedo baja.

Variables residuales: La Producción industrial EE. UU. (Nº 28; 0,3792) y el Petróleo Brent (Nº 15; 0,2756) han perdido peso relativo en este componente.

·Este segundo componente explica el 14,723% de la varianza, podría identificar la relación directa entre la actividad industrial y el estímulo monetario en el escenario post-COVID.

Variables con carga positiva: La Producción industrial en Europa (Nº 29; 0,7551) va ligada a la Masa monetaria M2 (Nº 23; 0,7420) y la M1 (Nº 22; 0,6892). Comparación crítica: En el pre-COVID, el dinero tenía signo negativo, ahora tienen el mismo signo. El Petróleo Brent (Nº 15; 0,5198) se suma a esta dinámica.

VARIABLES CON CARGA NEGATIVA: Destacan los Ingresos medios por hora en USA (Nº 1; -0,6338) y el Franco Suizo (Nº 2; -0,4836).

VARIABLES RESIDUALES: El S&P 500 (Nº 12; -0,1266) apenas aparece aquí, pudiendo demostrar que este es un factor de economía real y liquidez.

Con un 10,787% de la varianza, este tercer componente podría capturar los efectos secundarios de la pandemia en el estilo de vida y las finanzas.

VARIABLES CON CARGA POSITIVA: Une al Nasdaq 100 (Nº 11; 0,6811) con el Índice de precios de vivienda en EE. UU. (Nº 6; 0,6623) y el Diferencial de bonos (Nº 24; 0,6464).

VARIABLES CON CARGA NEGATIVA: Presentan cargas negativas significativas el Bitcoin (Nº 8; -0,4456), el S&P 500 (Nº 12; -0,4434) y el Nasdaq 100 (Nº 11; -0,4264).

VARIABLES RESIDUALES: El Bitcoin (Nº 8; 0,0775) y los Emergentes (Nº 10; 0,1210) no participan en este bloque, que es puramente de activos físicos y digitales de economías avanzadas.

-El último factor explica el 8,134% de la varianza y marca la línea roja entre la seguridad y el riesgo.

VARIABLES CON CARGA POSITIVA: Agrupa algunas divisas refugio tradicionales: Franco Suizo (Nº 2; 0,4791), Euro (Nº 16; 0,4271) y Yen Japonés (Nº 21; 0,3326), junto con el VIX (Nº 27; 0,3503).

VARIABLES CON CARGA NEGATIVA: el Bitcoin (Nº 8; -0,4456) y la bolsa (S&P 500; -0,4434 y Nasdaq; -0,4264). Esto podría demostrar que, aunque en el PC1 el Bitcoin parece una acción más, ante tensiones extremas el mercado lo sigue castigando como un activo de riesgo.

VARIABLES RESIDUALES: La Producción industrial Europa (Nº 29; 0,2431) es marginal, ya que el pánico financiero de corto plazo suele ignorar los datos de producción.

6.3. PCA con variables cripto

En este apartado extra vamos a analizar para el periodo post-COVID y con una temporalidad desde Agosto del 2020 a Diciembre del 2025, la inclusión en el PCA de las variables cripto. Debido a que las variables criptos, excepto Bitcoin, carecen de una gran temporalidad de datos.

A su vez, para poder seguir con la misma estructura anterior, en la siguiente tabla aparecerán las nuevas variables incluidas al final, para no distorsionar la codificación de las mismas.

Nº Variable	Nombre de la variable
1	Ingresos medios por hora (USA)
2	Franco Suizo/Dólar
3	Yuan Chino/Dólar
4	Índice de Precios al Consumidor (USA)
5	Índice de Precios al Consumidor menos alimentos y energía (USA)
6	Índice de precios de vivienda (USA)
7	Precio del cobre
8	Precio Bitcoin
9	Euro Stoxx50
10	MSCI Emerging Markets
11	Nasdaq 100
12	S&P 500
13	Precio Gas natural
15	Precio Petróleo Brent
16	Euro/Dólar
17	Indicador de clima empresarial (Europa)
18	Libra Esterlina/Dólar
19	Índice de Precios al Consumidor menos alimentos y energía (Europa)
20	Índice de Precios al Consumidor (Europa)
21	Yen Japonés/Dólar
22	Masa monetaria M1 (USA)
23	Masa monetaria M2 (USA)
24	Diferencial entre el bono a 10años y el de 3 meses (USA)
25	Tasa desempleo (Europa)
26	Sentimiento del consumidor (USA)
27	Índice de volatilidad
28	Producción industrial (USA)

29	Producción industrial (Europa)
30	Precio Binance coin
31	Precio Ethereum
32	Precio Solana
33	Precio XRP

Tabla 8. Codificación de las variables utilizadas en la estimación PCA con variables cripto. Fuente: elaboración propia.

En la siguiente imagen, y siguiendo la misma estructura anterior, tenemos el resultado del PCA.

Dimensión	Varianza	% de Varianza	% Acumulado
Dim.1	7,019	21,936%	21,936%
Dim.2	4,602	14,381%	36,316%
Dim.3	3,240	10,124%	46,441%
Dim.4	2,571	8,036%	54,476%
Dim.5	1,908	5,961%	60,438%
Dim.6	1,619	5,059%	65,497%
Dim.7	1,431	4,471%	69,968%
Dim.8	1,214	3,793%	73,761%
Dim.9	1,101	3,441%	77,202%
Dim.10	0,988	3,088%	80,291%

Tabla 9. Resultado PCA con variables cripto en R-studio. Fuente:Elaboración propia.

Para este modelo y siguiendo el mismo criterio(Bai and Ng) el número óptimo de factores a escoger son:

Criterio	Número óptimo de factores
IC1	4
IC2	3
IC3	10

Tabla 10. Criterio de Bai and Ng en R-studio con variables cripto. Fuente:elaboración propia.

Finalmente, vemos que las cargas de las variables sobre cada factor son las siguientes:

Nº Variable	Dim.1	Dim.2	Dim.3
1	-0,06149685	0,11447163	0,4098372393
2	0,55811255	-0,43633644	0,50760265
3	0,63028938	-0,13270771	0,4384742407
4	-0,37196185	0,44539876	0,4548453502
5	-0,40460428	0,25122026	0,4170248552
6	-0,16617286	0,60171805	0,3418220432
7	0,57526846	0,06816164	0,3222192266
8	0,58281638	0,29976058	-0,4334606539
9	0,67843392	0,17272555	0,0787117816
10	0,78778538	-0,10830547	0,2400367212
11	0,75184157	0,13303419	-0,0753945235
12	0,80126986	0,19731457	0,0140829701
13	-0,1218802	0,21508496	-0,0306606601
15	0,13029305	0,45463418	0,185097034
16	0,64771274	-0,41670533	0,488776166
17	-0,40418001	0,3866534	0,4687252835
18	0,74439473	-0,25823891	0,4336446021
19	-0,38368916	-0,18148935	0,0548421933
20	-0,41995532	-0,10713666	0,1313161423
21	0,5705304	-0,33826907	0,3291776725
22	0,13520979	0,74026725	0,1846323416
23	0,2036449	0,73531102	0,1612816356
24	-0,29842112	0,62607635	0,4630513114
25	0,19436317	-0,29881187	-0,2947708802
26	0,12571684	0,65704484	0,0008637216
27	-0,38608434	-0,11484873	0,1066371886
28	0,08031556	0,20296682	0,073592416

29	-0,09691819	0,21240555	0,0480838783
30	0,40537653	0,43187346	-0,3478776347
31	0,5884406	0,44497641	-0,3967415752
32	0,43603335	0,44137367	-0,3923035148
33	0,36393177	0,28693463	-0,3736111649

Tabla 11. Cargas factoriales de las variables anteriores y cripto en R-studio. Fuente: elaboración propia.

·Este primer componente explica el 21,936% de la varianza total.

Variables con carga positiva: Los índices bursátiles lideran este bloque, destacando el Nasdaq 100 (Nº 11; 0,8012), el MSCI Emerging Markets (Nº 10; 0,7877) y el S&P 500 (Nº 12; 0,7518). Esta tendencia se traslada al mercado cripto con Bitcoin (Nº 8; 0,5828) y Ethereum (Nº 31; 0,5884), mientras que la Libra Esterlina (Nº 18; 0,7443) aporta un peso significativo al componente.

Variables con carga negativa: Las variables que se mueven de forma inversa a son el IPC de Europa (Nº 20; -0,4199), el VIX (Nº 27; -0,3860) y el IPC de EE. UU. (Nº 4; -0,3719).

Variables residuales: La Masa monetaria M1 (Nº 22; 0,1352) y el precio del Gas natural (Nº 13; -0,1218) apenas tienen participación, manteniéndose prácticamente neutrales.

·Este segundo componente explica el 14,381% de la varianza y podría identificar la relación directa entre las condiciones monetarias y el rendimiento de las altcoins³.

Variables con carga positiva: Destacan con gran fuerza los agregados monetarios de EE. UU., la M1 (Nº 22; 0,7402) y la M2 (Nº 23; 0,7353), junto al Sentimiento del consumidor (Nº 26; 0,6570). En este escenario, criptomonedas como Solana (Nº 32; 0,4413) y Binance Coin (Nº 30; 0,4318) mantienen su relevancia por la liquidez disponible.

Variables con carga negativa: Las mayores presiones se encuentran en el Franco Suizo (Nº 2; -0,4363) y el Euro (Nº 16; -0,4167).

Variables residuales (pérdida de peso): Aquí es donde el mercado bursátil desaparece respecto al primer componente; el Nasdaq 100 (Nº 11; 0,1330) y el S&P 500 (Nº 12;

³ El término viene de la unión de alternative y coin, y se utiliza para designar a cualquier criptomoneda que no sea Bitcoin.

0,1973) pierden casi toda su fuerza, sugiriendo que este componente no depende de la bolsa, sino de la masa monetaria. El Bitcoin (Nº 8; 0,2997) también pierde la mitad de su peso en comparación con el componente anterior.

·Este tercer componente explica el 10,124% de la varianza.

Variables con carga positiva: El Franco Suizo (Nº 2; 0,5076) y el Euro (Nº 16; 0,4887) muestran una relación directa con el IPC USA (Nº 4; 0,4548) y el Diferencial de bonos (Nº 24; 0,4630).

Variables con carga negativa: Todo el sector cripto se vuelve negativo, destacando Bitcoin (Nº 8; -0,4334), Ethereum (Nº 31; -0,3967) y Solana (Nº 32; -0,3923).

Variables residuales (pérdida de peso): Los grandes protagonistas del primer componente desaparecen por completo: el S&P 500 (Nº 12; 0,0140) y el Nasdaq 100 (Nº 11; -0,0753) tienen cargas nulas.

6.4. Regresión lineal de los componentes sobre los rendimientos del oro

Finalmente, y para concluir este apartado de resultados, se van a extraer los componentes de las anteriores estimaciones de PCA, solo el periodo pre-COVID y post-COVID, no se van a incluir la extensión de variables cripto, debido a la poca cantidad de observaciones.

· pre-COVID

Estos son los resultados de la regresión lineal del único factor extraído sobre el rendimiento del oro en el periodo pre-COVID.

Variable / Estadístico	Estimación / Valor	Error Estándar	Estadístico t / F	p-valor
Constante	0,003575	0,004642	0,770	0,444
PC1	-0,001216	0,001774	-0,685	0,496
R-cuadrado (R ²)	0,007768	-	-	-
Estadístico F	0,4697	-	-	0,4958

Tabla 12. Resultado de la regresión lineal pre-COVID en R-studio. Fuente: elaboración propia.

En cuanto a la relación individual de las variables, el coeficiente estimado para PC1 es de -0,001216. Sin embargo, este valor carece de significancia estadística, ya que su p-valor es de 0,496, situándose muy por encima del umbral convencional de 0,05.

La capacidad del modelo para explicar las variaciones en el precio del oro es prácticamente nula. El coeficiente de determinación R-cuadrado (Multiple R-squared) es de apenas 0,007768, lo que significa que el modelo solo explica el 0,77% de la variabilidad de los datos. Más notable aún es el R-cuadrado ajustado (Adjusted R-squared), que presenta un valor negativo de -0,00877, lo que indica que la inclusión del factor PC1 no añade valor predictivo al modelo comparado con un modelo básico sin variables.

-Post covid

Variable / Estadístico	Estimación	Error Estándar	Estadístico t / F	p-valor
Constante	0,013626	0,004070	3,348	0,001388 **
PC1	0,006425	0,001536	4,182	9,24e-05 ***
PC2	-0,005289	0,002004	-2,638	0,010518 *
PC3	-0,002456	0,002342	-1,049	0,298404
PC4	0,010316	0,002697	3,826	0,000306 ***
R-cuadrado (R ²)	0,3933	-	-	-
Estadístico F	10,05	-	-	2,474e-06 ***

Tabla 13. Resultado de la regresión lineal post-covid en R-studio. Fuente: elaboración propia.

En el escenario posterior a la pandemia, la estructura del modelo revela que los rendimientos logarítmicos del oro responden de manera significativa a tres de los cuatro componentes analizados:

-PC1 y PC4 (Influencia Positiva): Ambos componentes muestran una relación positiva y altamente significativa. Los componentes PC1 y PC4 tienen un coeficiente de (0,006425 y 0,010316). Esto indica que los factores subyacentes capturados por estos componentes son actualmente motores clave que explican parte de la variación de los rendimientos del oro.

-PC2 (Influencia Negativa): Este componente resulta significativo, al 0,05 a diferencia de los componentes PC1 y PC4 que lo son al 0,001, pero con un coeficiente

negativo(-0,005289). Esto sugiere que los movimientos en las variables representadas por el PC2 tienden a ejercer una presión a la baja sobre la variación de los rendimientos del oro.

-PC3: Es el único componente que no muestra evidencia estadística de afectar el rendimiento (p-valor de 0,298), lo que implica que la información capturada por este factor es irrelevante para explicar la variabilidad del oro en este periodo.

A diferencia del periodo previo, el modelo actual posee una capacidad predictiva notable. El coeficiente de determinación R-cuadrado(Multiple R-squared) es de 0,3933, lo que significa que el 39,33% de la variabilidad de los rendimientos logarítmicos del oro es explicada por la combinación de estos cuatro componentes principales. El R-cuadrado ajustado(Adjusted R-squared) (0,3541) confirma que esta capacidad explicativa es sólida y no es producto de un sobreajuste por el número de variables.

El modelo en su conjunto es altamente robusto y estadísticamente significativo. El estadístico F alcanza un valor de 10,05 con un p-valor cercano a 0.

7. CONCLUSIONES

-La Estructura Económica del Periodo Pre-COVID

En la etapa anterior a la crisis sanitaria, los resultados del análisis de componentes principales revelan un entorno financiero de relativa simplicidad estructural, donde un único factor dominante es capaz de explicar el 24,457% de la varianza total de la muestra. Este escenario sugiere la existencia de un ciclo de crecimiento orgánico y sincronizado, donde los mercados de valores y la actividad económica real avanzaban en la misma dirección. Es razonable suponer que el motor principal de este periodo era el sector corporativo y tecnológico estadounidense, dada la elevada carga factorial observada en variables como el S&P 500 (Nº 12; 0,8494) y el Nasdaq 100 (Nº 11; 0,7109). Esta dinámica se extendía al continente europeo de forma casi idéntica, reflejada en el Euro Stoxx 50 (Nº 9; 0,7665), lo que permitiría hipotetizar una integración profunda entre ambos bloques económicos durante este ciclo expansivo.

Este crecimiento no se limitaba al ámbito financiero, sino que presentaba una base tangible en la producción industrial y el sector energético. La fuerte presencia del Petróleo Brent (Nº 15; 0,8032) y los datos de producción industrial en Europa (Nº 29;

0,6441) y EE. UU. (Nº 28; 0,4827) refuerzan la idea de una industria funcionando a pleno rendimiento. Asimismo, se podría interpretar que la economía gozaba de una inercia propia que no dependía de estímulos monetarios extraordinarios, considerando la relación inversa del componente con la masa monetaria M2 (Nº 23; -0,7301) y M1 (Nº 22; -0,5059). En este contexto de estabilidad, activos como el Bitcoin (Nº 8; 0,2604) mantenían una relevancia marginal, sin llegar a formar parte del núcleo de variables que definían el sentimiento global de mercado. Esta tendencia de los activos a moverse hacia un factor común de crecimiento real es coherente con la literatura técnica, que señala cómo los precios de las materias primas tienden a revertirse hacia un factor central, aunque la velocidad de dicha reversión sea lenta.

-Complejidad y Fragmentación en el Escenario Post-COVID

Tras la pandemia, los resultados evidencian una estructura económica significativamente más fragmentada, en la que se requieren cuatro factores para explicar el 58,708% de la varianza total. El primer componente, que abarca el 25,064% de la varianza, muestra un cambio en la percepción de los indicadores económicos tradicionales. Es plausible suponer que la inflación ha dejado de ser interpretada como un signo de salud económica para convertirse en una amenaza, ya que el IPC de Europa (Nº 20; -0,5163) presenta ahora una carga negativa, posiblemente por el temor a subidas de tipos de interés que generen inestabilidad bursátil. A su vez, el segundo componente (14,723%) identifica una nueva dinámica donde la producción industrial en Europa (Nº 29; 0,7551) aparece estrechamente ligada a la masa monetaria M2 (Nº 23; 0,7420) y M1 (Nº 22; 0,6892). Este hallazgo permitiría hipotetizar que la economía real postpandemia depende de forma crítica de los estímulos y la liquidez inyectada por los bancos centrales.

Esta evolución hacia una mayor complejidad en los mercados de derivados y futuros es una característica que la literatura contemporánea subraya, destacando que los métodos tradicionales de predicción pueden ser insuficientes para captar estos cambios dinámicos. La fragmentación del mercado sugiere que factores latentes, como la liquidez y el sentimiento de riesgo, han cobrado un protagonismo superior a la relación industrial observada anteriormente.

-La Integración de los Criptoactivos en el Sistema Financiero

Al incluir variables cripto adicionales en el análisis post-COVID, el modelo revela una integración notable de estos activos en el sentimiento de riesgo global. El primer componente (21,936%) agrupa a los índices bursátiles tradicionales, como el Nasdaq

100 (Nº 11; 0,8012), con el Bitcoin (Nº 8; 0,5828) y el Ethereum (Nº 31; 0,5884). Es factible suponer que el mercado trata actualmente a las criptomonedas líderes como activos procíclicos de riesgo, similares a las acciones tecnológicas de crecimiento. Por otro lado, el segundo componente (14,381%) vincula la masa monetaria M1 (Nº 22; 0,7402) y M2 (Nº 23; 0,7353) con *altcoins* como Solana (Nº 32; 0,4413) y Binance Coin (Nº 30; 0,4318), lo que podría indicar que el rendimiento de estos activos digitales depende principalmente de la liquidez monetaria disponible y no de la marcha de la bolsa general.

No obstante, cuando el mercado enfrenta tensiones, como las capturadas en el tercer componente (10,124%), todo el sector cripto manifiesta cargas negativas significativas (Bitcoin Nº 8: -0,4334; Ethereum Nº 31: -0,3967; Solana Nº 32: -0,3923). Se podría hipotetizar que, ante la incertidumbre, los inversores siguen castigando a los activos digitales como elementos de riesgo extremo, prefiriendo refugios tradicionales como el Franco Suizo (Nº 2; 0,5076).

•El Caso del Oro

El análisis de regresión sobre el oro ofrece la prueba más clara de la transformación del mercado. En el periodo pre-COVID, la capacidad del modelo para explicar al oro era nula (R-cuadrado ajustado de -0,00877 y p-valor de 0,496), operando de forma independiente a la bolsa y la industria. Sin embargo, en el escenario post-COVID, el modelo alcanza un R-cuadrado de 0,3933, explicando casi el 40% de su variabilidad.

En este nuevo contexto, los componentes actúan de forma contrapuesta. Mientras que el PC1 (crecimiento/riesgo; coeficiente 0,0064) y el PC4 (seguridad; coeficiente 0,0103) son motores positivos, el PC2 presenta un coeficiente negativo y significativo (-0,005289). Es razonable suponer que, dado que el PC2 representa el bloque de "Producción Industrial y Liquidez Monetaria", su signo negativo indica que cuando la economía real se acelera gracias a los estímulos, el oro pierde atractivo como activo refugio. Por contra, el PC3 resulta irrelevante (p-valor 0,298), lo que implica que la información de ese factor no afecta a la variabilidad del metal. Esto confirma que el oro ha vuelto a integrarse en la macroeconomía, pero de forma selectiva: se ve impulsado por el riesgo global y la búsqueda de seguridad, pero se ve frenado cuando la recuperación industrial y la expansión monetaria ganan tracción.

7.1. Conclusiones generales.

La presente investigación permite confirmar la premisa central que motivó este trabajo: la existencia de un quiebre estructural profundo en el sistema financiero global derivado de la crisis del COVID-19. Los resultados no solo validan esta hipótesis, sino que demuestran que las dinámicas que regían los comovimientos de los activos antes de 2020 han sido sustituidas por un nuevo orden de mayor complejidad y fragmentación.

La primera prueba de este cambio de régimen es la evolución de la dimensionalidad del mercado. El paso de una estructura monocéntrica a una multidimensional tras el estallido de la pandemia valida las tesis de Liu et al. (2025), quienes sostienen que la dinámica de los activos financieros es altamente variable en el tiempo y que los modelos de factores latentes son herramientas esenciales para capturar la naturaleza cambiante de los mercados modernos. Se puede concluir, por tanto, que la simplicidad del crecimiento industrial sincronizado de la etapa previa ha dado paso a un sistema donde la liquidez, el riesgo tecnológico y las expectativas inflacionarias operan como fuerzas independientes.

En cuanto a los motores de la economía, se ha observado una mutación en el papel de la masa monetaria. Mientras que en el periodo anterior el crecimiento se mostraba autónomo, los resultados actuales revelan un sistema donde la producción industrial depende intrínsecamente de los estímulos de los bancos centrales. Esta transformación ha facilitado la asimilación de los activos digitales en el epicentro del riesgo financiero. El Bitcoin ha dejado de ser una variable marginal para integrarse plenamente en el sentimiento bursátil global, comportándose como un activo procíclico. Sin embargo, en línea con el comportamiento histórico de los activos de riesgo extremo, el estudio sugiere que las criptomonedas aún no han alcanzado propiedades de refugio, ya que el mercado sigue castigándolas en episodios de alta volatilidad en favor de valores tradicionales como el Franco Suizo.

El análisis de regresión sobre el oro actúa como la evidencia definitiva de este quiebre estructural. La transición de un modelo sin ninguna capacidad explicativa a uno con una robustez notable en el periodo reciente demuestra que el oro ha vuelto a ser un activo reactivo a los fundamentos macroeconómicos. Como indican West y Wong (2014), los modelos de factores logran extraer una tendencia central que las variables individuales suelen omitir debido al ruido del mercado. Esta capacidad del modelo para identificar patrones a través del ruido postpandemia valida la elección metodológica de este trabajo y confirma que el oro ha recuperado su sensibilidad técnica ante el nuevo escenario.

Es determinante resaltar que, en este nuevo ciclo, el oro responde de forma selectiva a los distintos factores. La influencia negativa del componente vinculado a la producción industrial y la liquidez revela una dualidad crítica: el oro se beneficia de la incertidumbre global, pero pierde tracción cuando la expansión monetaria logra reactivar la economía real. Por el contrario, la falta de significancia estadística del tercer componente refuerza la idea de que el mercado ha seleccionado conductores muy específicos para el valor del metal.

En conclusión, se cumple la premisa inicial basada en los autores referenciados: la complejidad latente del mercado actual requiere un enfoque multifactorial. El trabajo certifica que el sistema financiero ha consolidado un paradigma definido por la fragmentación de los riesgos, la sensibilidad ante la inflación y una dependencia estructural de la liquidez global, factores que han reconfigurado permanentemente la forma en que el mercado valora activos estratégicos como el oro.

8. Bibliografía

- Bai, J. and Ng, S. (2002). Determining the number of factors in approximate factor models. *Econometrica*, 70(1):191–221.
- Blocher, J., Cooper, R., & Molyboga, M. (2016). *Benchmarking commodity investments* (SSRN Scholarly Paper No. 2744766). SSRN. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2744766
- Guevara, D. E. R., & Uribe, G. J. G. (2017). Principios de econometría. En *Instituto Tecnológico Metropolitano eBooks*. <https://elibro-net.sabidi.urv.cat/es/ereader/urv/105646>
- Hair, J. F., Anderson, R. E., Tatham, R. L., y Black, W. C. (1999). *Análisis multivariante* (5.ª ed.). Prentice Hall.
- Liu, Y., Zhou, H., & Yang, H. (2025). Latent factor models for the Chinese commodity futures markets. *Pacific-Basin Finance Journal*, 93, 102890. <https://www.sciencedirect.com/science/article/abs/pii/S0927538X25002276?via%3Dihub>
- Manjón Antolín, M. C. *Estadística y Econometría I* (Apuntes de clase). Departamento de Economía, Universitat Rovira i Virgili.
- Quiroga, C. y Villalobos, A. (2015). Análisis del comportamiento bursátil de las principales Bolsas Financieras en el mundo usando el análisis multivariado (análisis de componentes principales PCA) para el período 2011 a 2014. *Revista CEA*, 1(2), 25-36.
- Romero Béjar, J. L. (2023). *Tema 3: Análisis de componentes principales (ACP)* (Material de curso). Repositorio Institucional de la Universidad de Granada.
- West, K. D., & Wong, K. (2013). A factor model for co-movements of commodity prices. *Journal Of International Money And Finance*, 42, 289-309. <https://www.sciencedirect.com/science/article/abs/pii/S0261560613001186?via%3Dihub>

9. Anexos

Anexo I. Tabla de variables

Tabla de todas las variables utilizadas en el trabajo, con nombre, procedencia y transformación realizada.

Nombre de la serie	Url	Frecuencia	Unidades	Corrección estacionalidad	Transformación
M1 money stock measure	https://www.federalreserve.gov/datadownload/Download.aspx?rel=H6&series=5a4eff00cf71261de46fe6ff1589c983&filetype=csv&label=include&layout=seriescolumn&from=01/01/2015&to=12/31/2025	Mensual	USD 1*10e9	SI	primera diferencias del logaritmo
M2 money stock measure	https://www.federalreserve.gov/datadownload/Download.aspx?rel=H6&series=c863875070a5c89ce5f546b8f9f787cf&filetype=csv&label=include&layout=serieslist&from=01/01/2015&to=12/31/2025	Mensual	USD 1*10e9	SI	primera diferencias del logaritmo
10-Year Treasury Constant Maturity Minus 3-Month Treasury Constant Maturity	https://fred.stlouisfed.org/series/T10Y3M	Mensual	porcentaje	NO	Ninguna
EUR/USD	https://www.investing.com/currencies/eur-usd-historical-data	Mensual	USD	NO	primera diferencias del logaritmo
GBP/USD	https://www.investing.com/currencies/gbp-usd-historical-data	Mensual	USD	NO	primera diferencias del logaritmo
CHF/USD	https://www.investing.com/currencies/chf-usd-historical-data	Mensual	USD	NO	primera diferencias del logaritmo
JPY/USD	https://www.investing.com/currencies/jpy-usd-historical-data	Mensual	USD	NO	primera diferencias del logaritmo
CNY/USD	https://www.investing.com/currencies/cny-usd-historical-data	Mensual	USD	NO	primera diferencias del logaritmo
Consumer Price Index for All Urban Consumers (CPI-U) less food and energy	https://data.bls.gov/dataViewer/view/timeseries/CUSR000SA0L1E us city average	Mensual	Promedio de 1982-1984 = 100	SI	primera diferencias del logaritmo
Consumer Price Index for All Urban Consumers (CPI-U) All items	https://data.bls.gov/dataViewer/view/timeseries/CUSR000SA0 us city average	Mensual	Promedio de 1982-1984 = 100	SI	primera diferencias del logaritmo
Oro precio	https://es.investing.com/commodities/gold-historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
Cobre precio	https://es.investing.com/commodities/copper-historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
Gas natural precio	https://es.investing.com/commodities/natural-gas-historical-data	Mensual	Usd	NO	primera diferencias del logaritmo

Petroleo brent precio	https://es.investing.com/commodities/brent-oil-historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
Industrial Production: Total Index	https://fred.stlouisfed.org/series/INDPRO	Mensual	Indice en base 2017	SI	primera diferencias del logaritmo
HICP all items europa	https://ec.europa.eu/eurostat/databrowser/view/prc_hicp_midx__custom_20733253/default/table	Mensual	Indice base 2015	SI	primera diferencias del logaritmo
HICP - All-items excluding energy and unprocessed food	https://ec.europa.eu/eurostat/databrowser/view/prc_hicp_midx__custom_20733320/default/table	Mensual	Indice base 2015	SI	primera diferencias del logaritmo
European unemployment rate	https://ec.europa.eu/eurostat/databrowser/view/UNE_RT_M__custom_20781098/default/table	Mensual	Porcentaje	SI	primera diferencias del logaritmo
Production in industry	https://ec.europa.eu/eurostat/databrowser/view/sts_inpr_m__custom_20810444/default/table	Mensual	Indice base 2021	SI	primera diferencias del logaritmo
Nasdaq 100	https://es.investing.com/indices/nq-100-historical-data	Mensual	usd	NO	primera diferencias del logaritmo
Sp500	https://es.investing.com/indices/us-spx-500-historical-data	Mensual	usd	NO	primera diferencias del logaritmo
Eurostock 50	https://es.investing.com/indices/eu-stoxx50-historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
Msci emerging markets	https://es.investing.com/indices/msci-em-historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
CBOE Volatility Index: VIX	https://fred.stlouisfed.org/series/VIXCLS	Mensual	indice	NO	primera diferencias del logaritmo
S&P Cotality Case-Shiller U.S. National Home Price Index	https://fred.stlouisfed.org/series/CSUSHPNSA	Mensual	Indice	NO	primera diferencias del logaritmo
House price index europa	https://ec.europa.eu/eurostat/databrowser/view/prc_hpi_q/default/table?lang=en	Mensual	Indice	Base 2015 = 100	primera diferencias del logaritmo
Btc	https://es.investing.com/crypto/bitcoin/historical-data	Mensual	usd	NO	primera diferencias del logaritmo

Eth	https://es.investing.com/crypto/ethereum/historical-data	Mensual	usd	NO	primera diferencias del logaritmo
Solana	https://es.investing.com/crypto/solana/historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
Binance coin	https://es.investing.com/crypto/bnb/historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
xrp	https://es.investing.com/crypto/xrp/historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
Average Hourly Earnings of All Employees, Total Private	https://fred.stlouisfed.org/series/CES0500000003	Mensual	Dollars per hour	SI	primera diferencias del logaritmo
University of Michigan: Consumer Sentiment	https://fred.stlouisfed.org/series/UMCSENT	Mensual	Index 1966=100,	NO	Ninguna
Euro area business climate indicator	https://ec.europa.eu/eurostat/databrowser/view/ei_bsci_m_r2__custom_20782081/default/table	Mensual	Indice	SI	Ninguna

9. Anexos

Anexo I. Tabla de variables

Tabla de todas las variables utilizadas en el trabajo, con nombre, procedencia y transformación realizada.

Nombre de la serie	Url	Frecuencia	Unidades	Corrección estacionalidad	Transformación
M1 money stock measure	https://www.federalreserve.gov/datadownload/Download.aspx?rel=H6&series=5a4eff00cf71261de46fe6ff1589c983&filetype=csv&label=include&layout=seriescolumn&from=01/01/2015&to=12/31/2025	Mensual	USD 1*10e9	SI	primera diferencias del logaritmo
M2 money stock measure	https://www.federalreserve.gov/datadownload/Download.aspx?rel=H6&series=c863875070a5c89ce5f546b8f9f787cf&filetype=csv&label=include&layout=serieslist&from=01/01/2015&to=12/31/2025	Mensual	USD 1*10e9	SI	primera diferencias del logaritmo
10-Year Treasury Constant Maturity Minus 3-Month Treasury Constant Maturity	https://fred.stlouisfed.org/series/T10Y3M	Mensual	porcentaje	NO	Ninguna
EUR/USD	https://www.investing.com/currencies/eur-usd-historical-data	Mensual	USD	NO	primera diferencias del logaritmo
GBP/USD	https://www.investing.com/currencies/gbp-usd-historical-data	Mensual	USD	NO	primera diferencias del logaritmo
CHF/USD	https://www.investing.com/currencies/chf-usd-historical-data	Mensual	USD	NO	primera diferencias del logaritmo
JPY/USD	https://www.investing.com/currencies/jpy-usd-historical-data	Mensual	USD	NO	primera diferencias del logaritmo
CNY/USD	https://www.investing.com/currencies/cny-usd-historical-data	Mensual	USD	NO	primera diferencias del logaritmo
Consumer Price Index for All Urban Consumers (CPI-U) less food and energy	https://data.bls.gov/dataViewer/view/timeseries/CUSR000SA0L1E us city average	Mensual	Promedio de 1982-1984 = 100	SI	primera diferencias del logaritmo
Consumer Price Index for All Urban Consumers (CPI-U) All items	https://data.bls.gov/dataViewer/view/timeseries/CUSR000SA0 us city average	Mensual	Promedio de 1982-1984 = 100	SI	primera diferencias del logaritmo
Oro precio	https://es.investing.com/commodities/gold-historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
Cobre precio	https://es.investing.com/commodities/copper-historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
Gas natural precio	https://es.investing.com/commodities/natural-gas-historical-data	Mensual	Usd	NO	primera diferencias del logaritmo

Petroleo brent precio	https://es.investing.com/commodities/brent-oil-historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
Industrial Production: Total Index	https://fred.stlouisfed.org/series/INDPRO	Mensual	Indice en base 2017	SI	primera diferencias del logaritmo
HICP all items europa	https://ec.europa.eu/eurostat/databrowser/view/prc_hicp_midx__custom_20733253/default/table	Mensual	Indice base 2015	SI	primera diferencias del logaritmo
HICP - All-items excluding energy and unprocessed food	https://ec.europa.eu/eurostat/databrowser/view/prc_hicp_midx__custom_20733320/default/table	Mensual	Indice base 2015	SI	primera diferencias del logaritmo
European unemployment rate	https://ec.europa.eu/eurostat/databrowser/view/UNE_RT_M__custom_20781098/default/table	Mensual	Porcentaje	SI	primera diferencias del logaritmo
Production in industry	https://ec.europa.eu/eurostat/databrowser/view/sts_inpr_m__custom_20810444/default/table	Mensual	Indice base 2021	SI	primera diferencias del logaritmo
Nasdaq 100	https://es.investing.com/indices/nq-100-historical-data	Mensual	usd	NO	primera diferencias del logaritmo
Sp500	https://es.investing.com/indices/us-spx-500-historical-data	Mensual	usd	NO	primera diferencias del logaritmo
Eurostock 50	https://es.investing.com/indices/eu-stoxx50-historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
Msci emerging markets	https://es.investing.com/indices/msci-em-historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
CBOE Volatility Index: VIX	https://fred.stlouisfed.org/series/VIXCLS	Mensual	indice	NO	primera diferencias del logaritmo
S&P Cotality Case-Shiller U.S. National Home Price Index	https://fred.stlouisfed.org/series/CSUSHPNSA	Mensual	Indice	NO	primera diferencias del logaritmo
House price index europa	https://ec.europa.eu/eurostat/databrowser/view/prc_hpi_q/default/table?lang=en	Mensual	Indice	Base 2015 = 100	primera diferencias del logaritmo
Btc	https://es.investing.com/crypto/bitcoin/historical-data	Mensual	usd	NO	primera diferencias del logaritmo

Eth	https://es.investing.com/crypto/ethereum/historical-data	Mensual	usd	NO	primera diferencias del logaritmo
Solana	https://es.investing.com/crypto/solana/historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
Binance coin	https://es.investing.com/crypto/bnb/historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
xrp	https://es.investing.com/crypto/xrp/historical-data	Mensual	Usd	NO	primera diferencias del logaritmo
Average Hourly Earnings of All Employees, Total Private	https://fred.stlouisfed.org/series/CES0500000003	Mensual	Dollars per hour	SI	primera diferencias del logaritmo
University of Michigan: Consumer Sentiment	https://fred.stlouisfed.org/series/UMCSENT	Mensual	Index 1966=100,	NO	Ninguna
Euro area business climate indicator	https://ec.europa.eu/eurostat/databrowser/view/ei_bsci_m_r2__custom_20782081/default/table	Mensual	Indice	SI	Ninguna