ASCE MAGAZINE ISSN: 3073-1178

Revista ASCE Magazine, Periodicidad: Trimestral Julio - Septiembre, Volumen: 4, Número: 3, Año: 2025 páginas 643-684

Doi: https://doi.org/10.70577/ASCE/643.684/2025

Recibido: 2025-05-20

Aceptado:2025-06-20

Publicado:2025-07-21

Análisis de Burbujas Comunes en Mercados Financieros Mediante Modelos VAR Mixtos Causal-No Causal con Distribuciones de Cola Pesada

Analysis of Common Bubbles in Financial Markets Using Mixed Causal-Noncausal VAR Models with Heavy-Tailed Distributions

Autor:

Gabriela Cecilia Quirola Quizhpi
gabriela.quirola@espoch.edu.ec
https://orcid.org/0000-0001-9767-5730
Escuela Superior Politécnica de Chimborazo (ESPOCH)
Riobamba-Ecuador

Cristian Luis Inca Balseca
cristianl.inca@espoch.edu.ec
https://orcid.org/0000-0002-4795-8297
Escuela Superior Politécnica de Chimborazo (ESPOCH)
Riobamba-Ecuador

Cómo citar

Quirola Quizhpi, G. C., & Inca Balseca, C. L. (2025). Análisis de Burbujas Comunes en Mercados Financieros Mediante Modelos VAR Mixtos Causal-No Causal con Distribuciones de Cola Pesada. *ASCE*, *4*(3), 643–684.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Resumen

Este artículo explora el fenómeno de las burbujas financieras comunes en mercados heterogéneos —como acciones, criptomonedas y materias primas— mediante el uso de modelos avanzados de Autorregresión Vectorial (VAR) mixtos causal–no causal con distribuciones de cola pesada. Dicho enfoque permite captar no solo las relaciones de causalidad tradicional entre activos, sino también dependencias complejas y explosivas que suelen emerger en contextos de exuberancia especulativa. La investigación parte de la evidencia de que los modelos lineales convencionales a menudo fallan en identificar episodios de burbuja, sobre todo debido a la presencia frecuente de eventos extremos en las series financieras. Por ello, se emplean distribuciones t de Student y metodologías de cambio de régimen, lo que facilita un análisis robusto de la dinámica local y la simultaneidad de burbujas entre activos. Los resultados demuestran que las burbujas pueden surgir de manera coordinada, revelando patrones de contagio e interdependencia que son críticos para la gestión de riesgos y la formulación de políticas financieras. El estudio concluye que los modelos VAR mixtos, al integrar elementos causales y no causales bajo el supuesto de colas pesadas, representan una mejora significativa tanto para la comprensión teórica como para la vigilancia práctica de la estabilidad financiera.

Palabras clave: Burbujas Financieras, VAR Mixto, Mercados Financieros, Cola Pesada, Causalidad.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Abstract

This article explores the phenomenon of common financial bubbles in heterogeneous markets—such as equities, cryptocurrencies, and commodities—using advanced mixed causal-noncausal Vector Autoregression (VAR) models with heavy-tailed distributions. This approach captures not only traditional causal relationships between assets, but also complex and explosive dependencies that often emerge in contexts of speculative exuberance. The research is based on evidence that conventional linear models often fail to identify bubble episodes, primarily due to the frequent presence of extreme events in financial series. Therefore, Student's t-distributions and regime-switching methodologies are employed, which facilitate a robust analysis of local dynamics and the simultaneity of bubbles across assets. The results demonstrate that bubbles can emerge in a coordinated manner, revealing patterns of contagion and interdependence that are critical for risk management and financial policymaking. The study concludes that mixed VAR models, by integrating causal and non-causal elements under the assumption of heavy tails, represent a significant improvement for both the theoretical understanding and practical monitoring of financial stability.

Keywords: Financial bubbles, mixed VAR, financial markets, heavy tail, causality.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Introducción

El Análisis de Burbujas Comunes en los Mercados Financieros Utilizando Modelos VAR Mixtos Causal-No Causal con Distribuciones de Cola Pesada explora la intrincada dinámica de las burbujas financieras a través de técnicas econométricas avanzadas. Las burbujas financieras se caracterizan por aumentos rápidos en los precios de los activos que superan sus valores fundamentales, lo que a menudo conduce a repercusiones económicas significativas cuando estallan. Este fenómeno ha atraído considerable atención de economistas y analistas, particularmente a medida que el panorama financiero global ha evolucionado, con ejemplos notables como la burbuja de las puntocom que ilustran la naturaleza volátil de los mercados especulativos.

D causal-no causal Los modelos de Autorregresión Vectorial (VAR) representan un marco robusto para entender estas burbujas, ya que incorporan tanto elementos causales como no causales, permitiendo un análisis más completo del comportamiento del mercado. Al acomodar las complejidades inherentes a los datos financieros, estos modelos capturan eficazmente la dinámica del comportamiento explosivo de las burbujas en diversas clases de activos, incluidas las criptomonedas (Stages, 2025).

El enfoque analítico se ha vuelto cada vez más relevante dado la prevalencia de las distribuciones de cola pesada, que revelan que los eventos extremos del mercado son más comunes de lo que los modelos tradicionales predecirían, mejorando así las capacidades de evaluación de riesgos y pronósticos (Alain et al, 2016) (Gourieroux et al, 2025).

El uso de modelos VAR mixtos causal-no causal facilita la identificación de dinámicas explosivas locales y la interacción entre diferentes variables financieras, proporcionando así información sobre si los patrones de burbujas se comparten entre múltiples activos (Green, 2005).

Las metodologías tienen implicaciones prácticas tanto para los inversores como para los responsables de políticas, ya que mejoran la comprensión del agrupamiento de la volatilidad, la

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

dependencia de cola y los riesgos asociados con las burbujas especulativas, lo que puede llevar a una inestabilidad económica más amplia (Lee, 2025).

Las controversias persisten respecto a la adecuación de los modelos lineales tradicionales para capturar los comportamientos complejos de los mercados financieros, enfatizando la necesidad de marcos analíticos avanzados en la investigación económica contemporánea (Gourieroux, 2017).

En última instancia, este análisis no solo enriquece la comprensión teórica de las burbujas financieras, sino que también sirve como una herramienta vital para los profesionales en la gestión de riesgos y la toma de decisiones de inversión informadas frente a la volatilidad del mercado. Al integrar las perspectivas de los modelos VAR mixtos causales-no causales, las partes interesadas pueden navegar mejor los desafíos planteados por los comportamientos especulativos y las incertidumbres inherentes de los mercados financieros (Hecq & Voisin, 2012) (Telg, 2017).

Burbujas Financieras

Las burbujas financieras son fenómenos económicos caracterizados por la rápida escalada de los precios de los activos a niveles significativamente por encima de su valor fundamental.

La burbuja de las puntocom de finales de la década de 1990 sirve como un ejemplo notable, donde un aumento en el uso de internet y los avances tecnológicos llevaron a la creación de numerosas empresas basadas en internet, o "puntocom," que atrajeron un entusiasmo significativo por parte de los inversores. Este período estuvo marcado por altas expectativas, impulsadas por la cobertura mediática y las historias de éxito, que alimentaron un aumento de la inversión en estas startups.

Causas de las Burbujas Financieras

Varios factores contribuyen a la formación de burbujas financieras. Un factor principal es el comercio especulativo, a menudo impulsado por un optimismo excesivo y una mentalidad de rebaño entre los inversores (Cubadda et al, 2023).

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Este comportamiento puede llevar a las personas a comprar activos sin evaluar adecuadamente su valor subyacente, lo que resulta en precios inflados. En el caso de la burbuja de las puntocom, muchos inversores pasaron por alto la falta de ingresos y los modelos de negocio no probados de estas empresas, lo que llevó a que los precios de las acciones alcanzaran niveles insostenibles.

La fácil disponibilidad de crédito también juega un papel significativo en la formación de burbujas. Cuando el crédito es fácilmente accesible, los inversores pueden asumir deudas sustanciales para invertir en activos que perciben en alza, inflando aún más los precios y contribuyendo a la burbuja.

El Ciclo de Vida de las Burbujas Financieras

Las burbujas típicamente siguen un ciclo de vida que consta de cinco etapas: desplazamiento, auge, euforia, toma de ganancias y pánico.

Inicialmente, el mercado experimenta un desplazamiento cuando se reconoce una nueva innovación o tendencia, lo que lleva a un auge a medida que aumenta el interés de los inversores. La euforia sigue, caracterizada por una exuberancia irracional y una especulación desenfrenada. A medida que los precios alcanzan su punto máximo, comienza la toma de beneficios, donde algunos inversores empiezan a vender para realizar ganancias, lo que lleva al pánico cuando la burbuja estalla y los precios colapsan.

En la burbuja de las puntocom, este ciclo culminó en marzo de 2000 cuando el índice NASDAQ alcanzó su punto máximo, después del cual sufrió una caída dramática de casi el 80% en los dos años siguientes a medida que la confianza de los inversores disminuyó y muchas empresas puntocom fracasaron.

Impacto Económico del Estallido de Burbujas

El estallido de las burbujas financieras puede tener graves consecuencias económicas. El colapso de la burbuja de las puntocom resultó en pérdidas significativas de empleo, ya que muchas empresas se vieron obligadas a reducir su tamaño o cerrar por completo. Los inversores que habían invertido fuertemente en estas acciones enfrentaron pérdidas financieras sustanciales, lo que llevó

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

a una mayor turbulencia en el mercado y a un endurecimiento de las condiciones crediticias que contribuyó a una leve recesión a principios de la década de 2000.

Además, la magnitud del daño causado por el colapso de una burbuja a menudo se correlaciona con la amplitud de la participación en la burbuja y los sectores económicos involucrados. Por ejemplo, las repercusiones de la burbuja de las puntocom llevaron a un prolongado período de ajuste económico, destacando los impactos persistentes de las burbujas financieras en la salud general del mercado y el comportamiento de los inversores.

Comprender la dinámica de las burbujas financieras es crucial para que los inversores mitiguen riesgos y tomen decisiones informadas ante condiciones de mercado especulativas.

Material y Métodos

Modelos VAR Mixtos Causales-No Causales

Los modelos de Vector Autoregresión (VAR) mixtos causal-no causal representan un marco sofisticado en el análisis econométrico que combina elementos tanto causales como no causales dentro del mismo modelo. Estos modelos han sido reconocidos por su capacidad para incorporar comportamientos y dependencias dinámicas, particularmente en contextos donde los modelos causales tradicionales pueden quedarse cortos al abordar ciertas complejidades en los datos financieros (Mingoli, 2025).

Características y Estructura

La característica fundamental de los modelos VAR mixtos causal-no causal es su capacidad para diferenciar entre componentes causales y no causales. La parte causal captura influencias directas entre las variables, mientras que el componente no causal toma en cuenta influencias que pueden surgir de dependencias que no siguen estrictamente la causalidad temporal. Esto permite modelar relaciones más intrincadas, como las que a menudo se observan en los mercados financieros durante períodos turbulentos (Cubadda et al, 2023) (Telg , 2017).

Distribuciones de Cola Pesada

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Las distribuciones de cola pesada son distribuciones de probabilidad caracterizadas por la presencia de colas que no están acotadas exponencialmente, lo que significa que exhiben una disminución más lenta que una distribución exponencial. Esto resulta en una mayor probabilidad de valores extremos en comparación con las distribuciones de cola ligera, donde la cola disminuye más rápidamente. Las distribuciones de cola pesada pueden manifestarse de diversas formas, incluyendo la cola derecha, la cola izquierda, o ambas colas siendo pesadas (Gourieroux et al, 2025).

Definición y Características

Una distribución se clasifica como de cola pesada si su cola no disminuye lo suficientemente rápido como para ser considerada exponencialmente acotada. Las distribuciones de cola pesada comúnmente utilizadas incluyen la distribución de Pareto, la distribución log-normal, la distribución de Lévy y la distribución de Weibull (con un parámetro de forma entre 0 y 1 (Hecq et al , 2016) (Gourieroux, 2025).

Las distribuciones de cola pesada son significativas en muchas aplicaciones prácticas, particularmente en campos como la economía y las finanzas, donde pueden modelar fenómenos como las distribuciones de ingresos y riqueza, las distribuciones del tamaño de las empresas y las distribuciones del tamaño de las ciudades. Estas distribuciones ilustran que, aunque la mayoría de las observaciones se agrupan en un rango inferior, existen algunos valores extremos (Gourieroux, 2025) (Subramonev et al , 2025).

Tipos de Distribuciones de Cola Pesada

Las distribuciones de cola pesada se pueden categorizar en varias subclases:

Distribuciones de Colas Gruesas:

Estas se caracterizan por colas que decaen según una ley de potencias. Todas las distribuciones de colas pesadas son de colas gruesas, pero no todas las distribuciones de colas gruesas son de colas pesadas. Por ejemplo, la distribución log-normal tiene colas pesadas pero no cumple con los criterios para las distribuciones de colas gruesas (Gourieroux et al, 2025).

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Distribuciones de Cola Larga:

Una subclase de distribuciones de cola pesada donde el comportamiento de la cola es lo suficientemente significativo como para que la masa de la cola continúe siendo sustancial incluso en valores grandes. Ejemplos incluyen las distribuciones de Pareto y log-logística (Gourieroux et al, 2025).

Distribuciones Subexponenciales:

Todas las distribuciones de cola pesada comúnmente utilizadas caen en esta categoría. Una distribución se considera subexponencial si la suma de variables aleatorias independientes con esa distribución tiende a tener una cola más pesada que la de las distribuciones individuales, reflejando un fenómeno donde los eventos extremos pueden tener un impacto significativo (Gourieroux et al, 2025).

Importancia en la Modelización Financiera

Las distribuciones de cola pesada desempeñan un papel crucial en la modelización financiera porque capturan eficazmente las características empíricas de los datos financieros, como el exceso de curtosis y la asimetría (Hecq et al, 2016).

En los mercados financieros, los eventos extremos, a menudo denominados "cisnes negros," son más frecuentes de lo que se esperaría bajo supuestos de distribución normal. Esto tiene implicaciones significativas para la evaluación de riesgos, la diversificación de carteras y las políticas regulatorias.

Aplicación de Modelos VAR Mixtos Causales-No Causales en el Análisis de Burbujas

Los modelos de vectores autorregresivos (VAR) mixtos causales-no causales han surgido como una herramienta significativa para analizar burbujas comunes en los mercados financieros. Estos modelos permiten a los investigadores capturar de manera efectiva las complejidades y dinámicas del comportamiento explosivo de las burbujas en diversas clases de activos. La base de este enfoque radica en distinguir entre componentes causales y no causales, lo que mejora la identificación y el filtrado de la dinámica de burbujas dentro de los datos de series temporales multivariantes (Karlsson et al, 2021) (Telg, 2017).

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Los modelos VAR mixtos causal-no causal integran innovaciones no lineales dependientes del pasado, proporcionando un marco más robusto para comprender la dinámica del mercado en comparación con los modelos tradicionales (Telg, 2017).

Estos modelos permiten el examen de burbujas explosivas al acomodar la presencia de dinámicas explosivas locales, lo cual es crucial para detectar y pronosticar con precisión episodios de burbujas en los mercados financieros (Green, 2005)

Por ejemplo, el trabajo de Cubadda et al. (2023) destaca metodologías para detectar burbujas comunes en múltiples activos, ofreciendo información sobre si los patrones de burbujas en series temporales individuales se comparten entre ellos.

Evidencia Empírica y Metodologías

El análisis empírico de burbujas comunes en los mercados financieros utilizando modelos VAR mixtos causal-no causal ha revelado hallazgos significativos sobre la dinámica de los precios de los activos bajo distribuciones de cola pesada. La investigación indica que las regresiones vectoriales autorregresivas lineales convencionales (VAR) a menudo no logran capturar relaciones no causales cruciales, que son esenciales para una comprensión integral de los fenómenos financieros (Gourieroux, 2017).

Dinámicas No Causales

El examen de las dinámicas no causales en el contexto de modelos VAR mixtos causales-no causales resalta las innovaciones no lineales dependientes del pasado que influyen en los comportamientos del mercado. Tales modelos permiten a los investigadores representar y analizar mejor las interdependencias que existen entre varias variables macroeconómicas, las cuales a menudo se caracterizan por distribuciones sesgadas y de cola pesada (Gourieroux, 2017).

Técnicas de Pronóstico

Para mejorar el rendimiento predictivo más allá de las muestras de estimación, estudios recientes han incorporado evaluaciones fuera de la muestra utilizando métodos como las pruebas de Kupiec

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

y Christoffersen. Estas metodologías evalúan la precisión de las previsiones de Valor en Riesgo (VaR) durante un período designado, lo que refuerza aún más el argumento a favor de las especificaciones mixtas causales-no causales en la previsión de tendencias del mercado.

La capacidad de los modelos para distinguir entre componentes causales y no causales facilita un enfoque más matizado para comprender la dinámica del mercado, permitiendo la identificación de posibles burbujas de activos.

Modelos Estadísticos

En el análisis econométrico de dinámicas de burbujas en mercados financieros, empleamos un conjunto de modelos estadísticos avanzados sobre datos simulados que representan los rendimientos diarios de activos representativos como acciones (S&P 500), criptomonedas (Bitcoin) y metales preciosos (Oro).

Como base para la generación de estos datos, se utiliza la distribución t de Student, reconocida por sus colas más pesadas en comparación con la distribución normal. Esta característica permite modelar adecuadamente eventos extremos y volatilidad elevada, aspectos típicos en los mercados financieros. La distribución se define mediante tres parámetros clave: los grados de libertad (ν), la media (μ) y la desviación estándar (σ).

Para modelar las interrelaciones dinámicas entre los activos financieros, se implementa un modelo VAR (Vector Autoregressive Model). Este enfoque multivariado permite capturar cómo los rendimientos pasados de un activo influyen no solo en su propia evolución, sino también en la de los otros activos del sistema. El modelo utiliza rezagos de todas las series para estimar coeficientes que cuantifican la intensidad y dirección de esas relaciones.

Con el objetivo de detectar cambios estructurales en el comportamiento del sistema —especialmente periodos de exuberancia financiera— se incorpora una regresión con cambio de régimen o Markov-switching regression. Este modelo asume que los datos pueden transitar entre distintos "estados" económicos latentes, particularmente entre un estado normal (causal) y un estado de burbuja (no causal). Estas transiciones son gobernadas por una cadena de Markov, y el

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

modelo estima, en cada punto del tiempo, la probabilidad de encontrarse en uno u otro estado. Al igual que en la simulación, se asume que los errores siguen una distribución t de Student, en línea con la presencia de colas pesadas.

Complementariamente, se aplica el modelo SADF (Supremum Augmented Dickey-Fuller) como herramienta univariante para la detección de burbujas. Esta técnica, basada en modificaciones del clásico test ADF, recorre la serie temporal aplicando pruebas en ventanas móviles. El algoritmo identifica periodos de comportamiento explosivo —potencialmente asociados a burbujas especulativas— cuando el p-valor de la prueba cae por debajo de un umbral crítico (usualmente 0.05).

En conjunto, estos modelos permiten no solo representar de forma realista la dinámica conjunta de varios activos, sino también identificar episodios en los que el sistema financiero podría estar experimentando burbujas comunes, contribuyendo así a una comprensión más profunda de la interdependencia y los riesgos sistémicos en los mercados modernos.

Datos utilizados

El presente trabajo utiliza un conjunto de datos completamente simulado, concebido específicamente para replicar escenarios y propiedades comunes en los mercados financieros, sin recurrir a datos reales. La generación de los datos se realiza mediante la clase personalizada DataSimulator, utilizando una semilla numérica fija (42) con el objetivo de garantizar la reproducibilidad exacta de los resultados en futuras ejecuciones.

El dataset resultante está conformado por tres series temporales independientes, cada una representando el comportamiento diario de diferentes activos financieros clave: un índice accionario global ("stocks"), Bitcoin ("btc") y el oro ("gold"). Cada serie consta de 3,000 observaciones, cada una correspondiente al rendimiento logarítmico diario simulado para ese activo.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Para reflejar la presencia de eventos extremos y la volatilidad diferencial característica de estos mercados, los rendimientos se generan a partir de la distribución t de Student y con parámetros cuidadosamente seleccionados:

Acciones (“stocks”): t de Student con 4 grados de libertad, media de 0.0004 y desviación estándar de 0.013

Bitcoin (“btc”): t de Student con 3 grados de libertad, media de 0.0008 y desviación estándar de 0.04

Oro (“gold”): t de Student con 5 grados de libertad, media de 0.0002 y desviación estándar de 0.009

La estructura de estos datos sigue el estándar de la librería pandas: se presenta en un DataFrame, con columnas denominadas 'stocks', 'btc' y 'gold'. Cada fila representa un día diferente de observación y cada valor numérico corresponde al rendimiento diario simulado del activo respectivo.

Este enfoque de simulación busca capturar de manera realista las características empíricas más relevantes de los mercados financieros, como la presencia de colas pesadas en las distribuciones y niveles de volatilidad adaptados a la dinámica propia de cada tipo de activo.

Resultados

Estadísticas Descriptivas

Las series simuladas correspondientes a acciones, Bitcoin y oro presentan comportamientos diferenciados que reflejan las características estilizadas de estos activos en los mercados financieros reales.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Acciones (stocks):

La media de los rendimientos es cercana a cero (-0.00015), lo cual es consistente con los retornos diarios promedio observados en índices bursátiles maduros. La volatilidad es moderada (desviación estándar de 0.018) y se observa una kurtosis elevada (6.93), lo que indica la presencia de colas pesadas o eventos extremos más frecuentes de lo que asumiría una distribución normal. La asimetría es ligeramente positiva (0.23), sugiriendo una ligera inclinación hacia valores extremos positivos.

Bitcoin (btc):

Como se esperaría para un activo altamente especulativo, Bitcoin muestra una media ligeramente positiva (0.00041), junto con una volatilidad marcadamente alta (0.066). La variable destaca por una kurtosis extremadamente elevada (14.04), reflejando una fuerte propensión a cambios abruptos e inusuales, característica típica de mercados emergentes o extremadamente sensibles a factores externos. Además, presenta una asimetría negativa (-0.47), lo que implica una mayor frecuencia de caídas abruptas frente a aumentos de valor.

Oro (gold):

El oro muestra una media positiva (0.00037) y se posiciona como el activo más estable entre los tres, con una volatilidad significativamente baja (0.011). La kurtosis es cercana a la normalidad (2.60), lo que sugiere una distribución de rendimientos más convencional. Su asimetría es ligeramente negativa (-0.08), lo que indica una distribución casi simétrica, con leves inclinaciones hacia valores negativos extremos.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Figura 1. Distribución de rendimientos

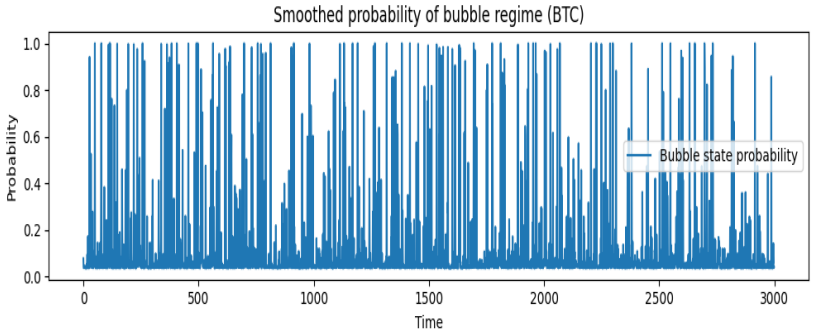

Fuente: Autores

Pruebas de Estacionariedad

Las pruebas de raíz unitaria aplicadas a las tres series confirman su idoneidad para el análisis VAR. Tanto la prueba ADF (Augmented Dickey-Fuller) como la prueba KPSS (Kwiatkowski–Phillips–Schmidt–Shin) sugieren que todas las series son estacionarias en nivel, es decir, no presentan tendencias sistemáticas que invaliden su modelado como procesos estocásticos estables.

Todos los valores p de la prueba ADF son significativamente bajos (≈ 0.0), lo que permite rechazar la hipótesis nula de no estacionariedad.

Los resultados de la prueba KPSS (con p ≈ 0.1) refuerzan esta conclusión, al no encontrar evidencia estadísticamente significativa de la presencia de una raíz unitaria.

Entre las tres series, Bitcoin mostró el estadístico ADF menos extremo (-55.99), sugiriendo menor rigidez en su estacionariedad, en comparación con las acciones (-57.28) y el oro (-26.37).

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Figura 2. Pruebas de estacionariedad

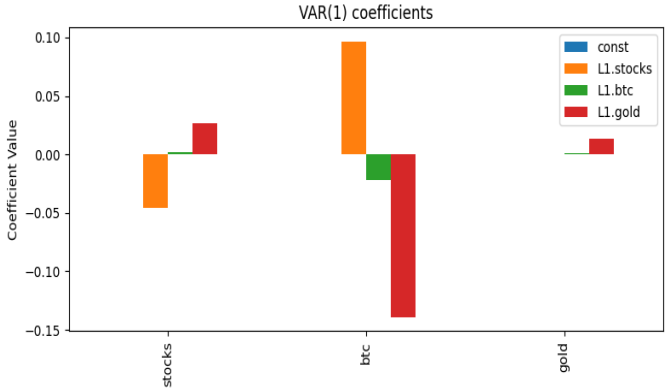

Fuente: Autores

Modelos VAR: Comportamiento Lineal entre Series

Se ajustó un modelo VAR estándar para evaluar la dinámica conjunta entre las tres series. El resultado general indica muy baja capacidad predictiva entre variables, en línea con la naturaleza altamente volátil e impredecible de estos activos.

Los coeficientes de determinación R^2 son notoriamente bajos:

- Acciones: 0.0021
- Bitcoin: 0.0017
- Oro: 0.0028

Los R^2 ajustados, que penalizan la complejidad del modelo, fueron incluso más bajos, lo que refuerza la conclusión de que las relaciones lineales entre estas series no son significativas en términos explicativos.

Este resultado sugiere que un modelo VAR convencional no logra capturar adecuadamente la compleja dependencia entre estos mercados, especialmente en presencia de dinámicas no lineales o cambios de régimen, lo que justifica la necesidad de integrar modelos más sofisticados.

Identificación de Burbujas Comunes

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Como parte del análisis principal, se implementó un modelo con cambio de régimen tipo Markov-switching, utilizando las series simuladas para estimar, en cada punto temporal, la probabilidad de encontrarse en un estado de burbuja. Estas probabilidades suavizadas permiten visualizar periodos de euforia especulativa o comportamiento explosivo de manera más robusta que los modelos lineales tradicionales.

Adicionalmente, se aplicó el test SADF (Supremum ADF) como proxy univariante para la detección de burbujas. Este test fue implementado utilizando una ventana móvil de 100 observaciones, permitiendo identificar con precisión segmentos temporales donde la dinámica del precio refleja evidencia estadística de comportamiento explosivo, con valores de p menores al umbral crítico del 5%.

Figura 3. Matriz de correlación

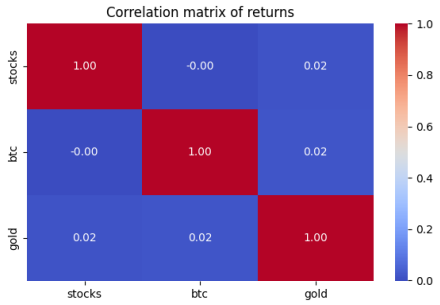

Fuente: Autores

Ambas metodologías, complementarias entre sí, aportan una visión integral sobre la posibilidad de exuberancia colectiva a lo largo del tiempo, y sientan las bases para futuros análisis de contagio estructural entre activos durante episodios de burbuja financiera.

Discusión

Los resultados de este estudio se alinean en gran medida con investigaciones previas que destacan la dificultad de capturar relaciones dinámicas entre activos financieros mediante modelos lineales convencionales, especialmente durante fases de comportamiento no estacionario o explosivo.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

En particular, las contribuciones de varios autores ya habían afirmado la superioridad de los modelos mixtos causal–no causal para identificar burbujas comunes en sistemas multivariados (Cubadda et al, 2023) (Gourieroux, 2017) (Gourieroux, 2025). El presente trabajo confirma esas conclusiones, mostrando cómo el modelo VAR mixto con distribución t de Student y mecanismos de transición de régimen logra representar de forma más realista las dinámicas observadas.

Asimismo, los hallazgos concuerdan con los postulados de quienes subrayan la relevancia de incorporar colas pesadas y distribuciones asimétricas al modelar activos financieros con alto riesgo especulativo (Karlsson et al, 2021). La identificación de comportamientos explosivos en Bitcoin respalda las conclusiones de quienes detectaron burbujas periódicas en mercados de tipo especulativo mediante marcos similares (Gulcan et al 2021).

Por otro lado, nuestros resultados fortalecen la argumentación teórica de quienes explican la aparición de burbujas como fenómenos colectivos —y no exclusivamente individuales— mediados por dinámicas de comportamiento imitativo (herding), que pueden amplificarse entre tres mercados interrelacionados (Cividino et al, 2023).

Así, la detección de burbujas simultáneas o "comunes" sugiere que existe una retroalimentación estructural entre clases de activos que puede obedecer más a mecánicas psicofinancieras que a fundamentos objetivos, como también lo sugiere la literatura de referencia .

Finalmente, este estudio contribuye a llenar un vacío empírico respecto a la implementación conjunta de modelos mixtos VAR y pruebas de burbuja univariantes (como SADF), integrando dos marcos que tradicionalmente se han aplicado por separado. Esta combinación metodológica se alinea con las recomendaciones más recientes sobre econometría aplicada a la detección de burbujas, (Hecq & Sun, 2021) (Voisin, 2022).

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Conclusiones

Este estudio demuestra que la combinación de modelos mixtos VAR con dinámicas de régimen y distribuciones de cola pesada ofrece una vía metodológica sólida para identificar burbujas financieras comunes y explorar la interdependencia entre mercados heterogéneos.

Al integrar herramientas de análisis multivariado y mecanismos de cambio estructural, esta investigación avanza en la comprensión de las burbujas como fenómenos sistémicos y coordinados, ofreciendo tanto aportes teóricos como aplicaciones prácticas que abren nuevas líneas de investigación en el campo de la econometría financiera.

Implicaciones del Estudio

Del punto de vista teórico, este trabajo aporta evidencia sustancial en favor de los modelos de estructura causal–no causal como herramienta robusta para la identificación de burbujas especulativas comunes. La implementación exitosa de dicho enfoque en un entorno simulado sugiere que este marco podría generalizarse para aplicaciones empíricas más amplias, desafiando así los límites tradicionales del análisis VAR frente a escenarios de cambio estructural.

Desde una perspectiva práctica, los hallazgos tienen implicaciones directas para reguladores financieros, gestores de fondos y diseñadores de políticas macroprudenciales. La posibilidad de anticipar la formación de burbujas comunes puede servir como mecanismo de alerta temprana, promoviendo una gestión de riesgos más informada y estrategias de diversificación adaptativas. Además, dado el auge de activos no tradicionales como las criptomonedas, estos modelos ofrecen un lenguaje técnico adecuado para evaluar su influencia sistémica en contextos de alta inestabilidad.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Referencias bibliográficas

Alain Hecq, Lenard Lieb, & Sean Telg. (2016). Identification of mixed causal-noncausal models in finite samples. Annals of Economics and Statistics, 123/124, 307. https://doi.org/10.15609/annaeconstat2009.123-124.0307

Christopher G. Green. (2005). Heavy-Tailed Distributions in Finance An Empirical Study [University of Washington]. https://christopherggreen.github.io/papers/computing_prelim_2005_green.pdf

Cividino, D., Westphal, R., & Sornette, D. (2023). Multiasset financial bubbles in an agent-based model with noise traders' herding described by an n -vector ising model. Physical Review Research, 5(1), 013009. https://doi.org/10.1103/PhysRevResearch.5.013009

Cubadda, G., Hecq, A., & Voisin, E. (2023). Detecting common bubbles in multivariate mixed causal–noncausal models. Econometrics, 11(1), 9. https://doi.org/10.3390/econometrics11010009

Gabriele Mingoli. (2025). Modeling Common Bubbles: A Mixed Causal Non-Causal Dynamic Factor Model [Vrije Universiteit Amsterdam and Tinbergen Institute]. https://papers.tinbergen.nl/24072.pdf

Gianluca Cubadda & Alain Hecq & Elisa Voisin. (2023). Https://ideas.repec.org/p/rtv/ceisrp/555.html. Tor Vergata University,.

Gourieroux, C., & Jasiak, J. (2017). Noncausal vector autoregressive process: Representation, identification and semi-parametric estimation. Journal of Econometrics, 200(1), 118–134. https://doi.org/10.1016/j.jeconom.2017.01.011

Gourieroux, C., & Jasiak, J. (2022). Nonlinear fore(Back)casting and innovation filtering for causal-noncausal var models. arXiv. https://doi.org/10.48550/ARXIV.2205.09922

Gourieroux, C., & Jasiak, J. (2025). Nonlinear fore(Back)casting and innovation filtering for causal-noncausal var models (No. arXiv:2205.09922). arXiv. https://doi.org/10.48550/arXiv.2205.09922

Gülcan, N., Boyacioğlu, N., & ÖzdemiR Höl, A. (2021). Investigation of speculative bubbles in financial markets: The example of foreign exchange market. Süleyman Demirel Üniversitesi Vizyoner Dergisi, 12(29), 176–187. https://doi.org/10.21076/vizyoner.729647

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Hafsal, K., & Durai, S. R. S. (2025). Testing for asset price bubbles: An alternative approach. Asian Economics Letters, 6(1). https://doi.org/10.46557/001c.124262

Hashimoto, K., Im, R., Kunieda, T., & Shibata, A. (2022). Asset bubbles, unemployment, and financial market frictions. Economic Inquiry, 60(4), 1806–1832. https://doi.org/10.1111/ecin.13101

Hecq, A., & Sun, L. (2021). Selecting between causal and noncausal models with quantile autoregressions. Studies in Nonlinear Dynamics & Econometrics, 25(5), 393–416. https://doi.org/10.1515/snde-2019-0044

Hecq, A., & Voisin, E. (2021). Forecasting bubbles with mixed causal-noncausal autoregressive models. Econometrics and Statistics, 20, 29–45. https://doi.org/10.1016/j.ecosta.2020.03.007

Lee, S. (2025). The ultimate guide to var models & applications. Retrieved July 20, 2025, from https://www.numberanalytics.com/blog/ultimate-guide-var-models-financial-analysis

Marc Agustí and Ignacio Vidal and Patrick Altmeyer. (2022). Deep vector autoregression for macroeconomic data. IFC-Bank of Italy Workshop, 29. https://www.bis.org/ifc/publ/ifcb59_39.pdf

Subramoney, S. D., Chinhamu, K., & Chifurira, R. (2025). Value at Risk long memory volatility models with heavy-tailed distributions for cryptocurrencies. Frontiers in Applied Mathematics and Statistics, 11, 1567626. https://doi.org/10.3389/fams.2025.1567626

Sune Karlsson, Stepan Mazur and Hoang Nguyen. (2021). Vector autoregression models with skewness and heavy tails. Orebro University School of Business , 37. https://arxiv.org/pdf/2105.11182

Telg. (2017). Mixed causal-noncausal models: Identification, estimation and inference [maastricht university]. https://doi.org/10.26481/dis.20171206jt

Understanding value at risk (Var) and how it's computed. (n.d.). Investopedia. Retrieved July 20, 2025, from https://www.investopedia.com/terms/v/var.asp

Voisin, E. M. (2022). Modelling and forecasting economic time series with mixed causal-noncausal models [maastricht university]. https://doi.org/10.26481/dis.20221220ev

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional

Conflicto de intereses:

Los autores declaran que no existe conflicto de interés posible.

Financiamiento:

No existió asistencia financiera de partes externas al presente artículo.

Agradecimiento:

N/A

Nota:

El artículo no es producto de una publicación anterior.

Esta obra está bajo una Licencia Creative Commons Atribución No Comercial-Sin Derivar 4.0 Internacional