



# **Transmisión de la política monetaria y su efecto sobre las decisiones de inversión: evidencia del impacto de la EFR en los índices S&P 500 y NASDAQ-100 (2018–2024)**

por

**Luis Carlos Molina y Felipe Serra**

Trabajo de grado presentado a la directiva de la carrera de Economía en cumplimiento de los requisitos para optar por el título de Economista por parte de la Pontificia Universidad Javeriana  
Cali

Director:

Mauricio Quiñones PhD

Pontificia Universidad Javeriana  
Facultad de Ciencias Económicas y Administrativas  
Cali- Valle del Cauca

# Declaración

Nosotros, **Felipe Serra Sánchez y Luis Carlos Molina** declaro que este trabajo de investigación es obra y esfuerzo propio. Todas las fuentes de información que se han consultado para realizar este documento han sido citadas y se ha hecho constar su procedencia.

Firma: \_\_\_\_\_

Fecha: 10 de noviembre, 2025

## Aprobación

... Por medio de la presente me permito comunicarle, que en mi calidad de director de trabajo de grado he leído detenidamente el informe final del trabajo de grado **“Impacto de las tasas efectivas de los Fondos Federales, en los índices de Nasdaq 100 y S&P 500 entre 2018 y 2024”**, realizado por los estudiantes de la Facultad de Ciencias Económicas y Administrativas de la Pontificia Universidad Javeriana Cali, **Felipe Serra Sánchez y Luis Carlos Molina**, identificados con la cédula de ciudadanía 1112039884/1110364945 y el ID institucional 8977244/8977144 respectivamente, y considero que cumple con todos los requisitos para ser presentado a evaluadores.

---

Tutor del proyecto.

## Resumen

Este estudio analiza la relación entre la política monetaria de la Reserva Federal (Fed), medida a través de la Effective Federal Funds Rate (EFFR), y el comportamiento de los principales índices bursátiles estadounidenses —S&P 500 y NASDAQ-100— durante el periodo 2018–2024. Se emplea información mensual y se segmenta el periodo en tres fases económicas: prepandemia (2018–2020.02), pandemia (2020.03–2021.12) y ajuste monetario (2022–2024), identificadas

mediante pruebas de quiebre estructural tipo Chow y breakpoints. Las series se transforman en log-diferencias o diferencias simples, garantizando estacionariedad a través de pruebas ADF, KPSS y ERS-DFGLS. En cada tramo se seleccionan rezagos óptimos con criterios de información (AIC/BIC) y se estiman modelos por Mínimos Cuadrados Ordinarios (MCO) con varianzas robustas tipo Newey–West, complementados con diagnósticos de autocorrelación, heterocedasticidad, normalidad y estabilidad de parámetros.

Los resultados muestran que la EFFR conserva un efecto contractivo y significativo sobre el S&P 500 durante la fase de ajuste monetario, coherente con el endurecimiento de la política de tasas. En contraste, el NASDAQ-100 evidencia una sensibilidad cambiante: negativa y rezagada durante la pandemia, pero positiva en el periodo 2023–2024, cuando narrativas de innovación tecnológica y expectativas de productividad moderaron el impacto de las tasas altas. Las variables de control —inflación (CPIAUCSL), desempleo (UNRATE) y producción industrial (INDPRO)— mantienen signos y comportamientos consistentes con la teoría macroeconómica, confirmando su papel en la transmisión entre la economía real y los mercados financieros.

En conjunto, los hallazgos sugieren que la EFFR es un proxy válido y dinámico de la postura monetaria siempre que se combine con segmentación temporal, rezagos óptimos y estimaciones robustas. La investigación aporta evidencia empírica sobre la asimetría temporal y sectorial en la respuesta de los mercados bursátiles a la política monetaria, y ofrece una base metodológica replicable para futuros estudios de transmisión monetaria en contextos de alta volatilidad.

**Palabras clave:** política monetaria, EFFR, S&P 500, NASDAQ-100, quiebre estructural, AIC/BIC, Newey–West, 2018–2024.

# Abstract

This study analyzes the relationship between the Federal Reserve's (Fed) monetary policy—measured through the Effective Federal Funds Rate (EFFR)—and the behavior of the main U.S. stock market indices, the S&P 500 and NASDAQ-100, during the 2018–2024 period. Monthly data are used, and the period is segmented into three economic phases: pre-pandemic (2018–2020.02), pandemic (2020.03–2021.12), and monetary tightening (2022–2024), identified through Chow and breakpoint structural break tests. The series are transformed into log-differences or simple differences, ensuring stationarity through ADF, KPSS, and ERS-DFGLS tests. For each segment, optimal lags are selected using information criteria (AIC/BIC), and the models are estimated using Ordinary Least Squares (OLS) with Newey–West robust variances, complemented by diagnostics for autocorrelation, heteroskedasticity, normality, and parameter stability.

The results show that the EFFR retains a contractionary and statistically significant effect on the S&P 500 during the monetary-tightening phase, consistent with the restrictive stance of interest rate policy. In contrast, the NASDAQ-100 displays a changing sensitivity: negative and lagged during the pandemic, but positive in 2023–2024, when narratives of technological innovation and productivity expectations mitigated the impact of high rates. The control variables—inflation (CPIAUCSL), unemployment (UNRATE), and industrial production (INDPRO)—maintain signs and behavior consistent with macroeconomic theory, confirming their role in the transmission mechanism between the real economy and financial markets.

Overall, the findings suggest that the EFFR is a valid and dynamic proxy for the monetary policy stance when combined with temporal segmentation, optimal lag selection, and robust estimation methods. The study provides empirical evidence of temporal and sectoral asymmetry

in the stock market's response to monetary policy and offers a replicable methodological basis for future research on monetary transmission under high-volatility contexts.

**Keywords:** monetary policy, EFR, S&P 500, NASDAQ-100, structural break, AIC/BIC, Newey–West, 2018–2024.

...

## Contenido

|                                                       |           |
|-------------------------------------------------------|-----------|
| <b>DECLARACIÓN</b> .....                              | <b>2</b>  |
| <b>APROBACIÓN</b> .....                               | <b>3</b>  |
| <b>RESUMEN</b> .....                                  | <b>5</b>  |
| <b>INTRODUCCIÓN</b> .....                             | <b>9</b>  |
| PLANTEAMIENTO DEL PROBLEMA .....                      | 11        |
| JUSTIFICACIÓN .....                                   | 14        |
| OBJETIVOS .....                                       | 15        |
| PREGUNTA DE INVESTIGACIÓN .....                       | 16        |
| <b>ALCANCES Y LIMITACIONES</b> .....                  | <b>17</b> |
| <b>MARCO TEÓRICO</b> .....                            | <b>19</b> |
| <b>METODOLOGÍA</b> .....                              | <b>29</b> |
| TIPO Y DISEÑO DE INVESTIGACIÓN .....                  | 29        |
| ESPECIFICACIÓN DE LOS MODELOS ECONÓMICOS .....        | 30        |
| TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS ..... | 34        |
| <b>ESTADÍSTICA DESCRIPTIVA</b> .....                  | <b>37</b> |
| <b>RESULTADOS</b> .....                               | <b>42</b> |
| <b>INTERPRETACIONES</b> .....                         | <b>53</b> |
| <b>CONCLUSIONES</b> .....                             | <b>69</b> |

|                  |    |
|------------------|----|
| ANEXOS .....     | 71 |
| REFERENCIAS..... | 80 |

## Introducción

El presente trabajo examina la relación entre la política monetaria de Estados Unidos y el comportamiento de sus principales índices bursátiles: el S&P 500 y el NASDAQ-100. El periodo 2018–2024 ofrece un entorno excepcionalmente dinámico para este análisis, al abarcar tres fases contrastantes: una etapa de estabilidad pre-pandemia, la disrupción económica generada por el COVID-19 con estímulos monetarios y fiscales sin precedentes, y una fase de normalización monetaria restrictiva caracterizada por incrementos sostenidos en la tasa de interés para enfrentar el repunte inflacionario. Este contexto permite observar cómo la relación entre las tasas de interés y los precios de las acciones cambia cuando el entorno macroeconómico y las expectativas del mercado también lo hacen.

El objetivo general de la investigación es analizar cómo las variaciones de la tasa efectiva de fondos federales (EFFR) se asocian con los rendimientos de los índices S&P 500 y NASDAQ-100, controlando por factores macroeconómicos clave como la inflación, el desempleo y la producción industrial. Se utiliza la EFFR en lugar de la tasa objetivo comunicada por la Reserva Federal, dado que refleja de forma más precisa las condiciones efectivas del mercado monetario y su dinámica mensual. Aunque el estudio no busca establecer causalidad estricta, sí procura aislar el canal de transmisión de la política monetaria y examinar su comportamiento bajo distintos regímenes económicos.

Según Bernanke y Gertler (1999), las variaciones en las tasas de interés impactan el valor presente de las acciones mediante el canal de tasas de descuento, afectando las decisiones de

inversión y la valuación de activos. Asimismo, Mishkin (2019) enfatiza que la política monetaria influye sobre los precios de los activos a través de la expectativa de flujos futuros y de la prima de riesgo. Estudios empíricos como los de Ehrmann y Fratzscher (2004) y Kuttner y Mosser (2002) documentan que los efectos de la política monetaria sobre los índices bursátiles no son homogéneos en el tiempo y varían según el estado del ciclo económico y las condiciones financieras. No obstante, pocos trabajos han incorporado la EFRR efectiva —en lugar de la tasa objetivo— y menos aún han explorado su efecto diferencial sobre índices de composición sectorial distinta, como el S&P 500 y el NASDAQ-100, durante un periodo de cambios estructurales como el comprendido entre 2018 y 2024. Este vacío empírico y metodológico motiva la presente investigación.

El diseño metodológico se distingue por su enfoque segmentado y dinámico. En lugar de asumir un vínculo estable entre tasas y precios, se implementan pruebas de quiebre estructural que permiten dividir la muestra en tres tramos (pre-COVID, COVID y post-COVID), de modo que los datos definan los cambios de régimen. Para cada tramo se seleccionan rezagos óptimos mediante criterios de información (AIC/BIC), y las estimaciones se realizan mediante modelos de Mínimos Cuadrados Ordinarios (MCO) con corrección de varianzas tipo Newey–West, garantizando robustez frente a autocorrelación y heterocedasticidad. Además, se aplican pruebas de estacionariedad (ADF, KPSS, ERS-DFGLS) y se transforman las series a diferencias o log-diferencias según su naturaleza, permitiendo trabajar con rendimientos e incrementos mensuales coherentes con la teoría económica.

A nivel empírico, el estudio plantea tres preguntas centrales:

- (i) ¿Cuál es la asociación entre la EFRR y los índices bursátiles una vez controlados los factores reales y nominales?

- (ii) ¿Cómo varía esta relación entre los distintos tramos económicos del periodo 2018–2024?
- (iii) ¿En qué medida los problemas estadísticos típicos de las series financieras (autocorrelación, heterocedasticidad o cambios estructurales) afectan la interpretación de los resultados?

El documento sigue un recorrido progresivo: inicia con la descripción de las fuentes y la construcción de las variables; continúa con el análisis descriptivo, las pruebas de estacionariedad y segmentación; y culmina con la estimación y diagnóstico de los modelos econométricos. Con este enfoque, se busca no solo obtener resultados estadísticamente sólidos, sino también ofrecer una lectura económica clara e interpretativa sobre la relación entre las decisiones de la Fed y el comportamiento de los mercados de capitales.

En definitiva, esta investigación combina rigor metodológico y relevancia práctica. Al documentar cómo varía la sensibilidad de los índices bursátiles frente a la política monetaria según el contexto económico, el trabajo contribuye a una comprensión más profunda de la transmisión de las tasas de interés hacia los activos financieros en un periodo caracterizado por shocks excepcionales, ajustes estructurales y cambios persistentes en la conducta de los inversionistas.

## Planteamiento del problema

Entre 2018 y 2024, la economía estadounidense atravesó tres fases macroeconómicas contrastantes: un periodo de estabilidad previa a la pandemia, la disrupción global del COVID-19 con expansión monetaria y fiscal sin precedentes, y una fase de ajuste monetario restrictivo iniciada en 2022 bajo la política de “higher for longer” para contener la inflación. Durante este ciclo, los mercados accionarios —representados por el S&P 500 y el NASDAQ-100—

experimentaron oscilaciones significativas tanto en sus niveles de precios como en su sensibilidad frente a la información macroeconómica. En este contexto, surge una pregunta central para la academia, los responsables de política y los inversionistas:

¿cómo varía la asociación entre la tasa efectiva de fondos federales (EFFR) y el desempeño de los principales índices bursátiles de Estados Unidos cuando se reconocen explícitamente los cambios de régimen ocurridos entre 2018 y 2024?

La EFFR, al reflejar el costo efectivo del dinero en el mercado interbancario, es el instrumento operativo más inmediato de la política monetaria de la Reserva Federal. Sin embargo, su efecto sobre los precios de los activos financieros no es estable: depende de la fase del ciclo, de las expectativas inflacionarias, de la liquidez global y del entorno de política fiscal. En fases expansivas, una subida moderada de tasas puede no alterar sustancialmente las valoraciones si predomina una narrativa de crecimiento; en cambio, en contextos de contracción o desinflación, el canal financiero tiende a dominar, amplificando el impacto negativo de la política monetaria sobre los precios accionarios. Por ello, suponer que la relación EFFR–mercado es constante en el tiempo conduce a interpretaciones sesgadas, especialmente cuando la estructura temporal de la economía exhibe quiebres estructurales que modifican los parámetros de transmisión.

A pesar del amplio cuerpo de literatura sobre los efectos de la política monetaria en los activos financieros, subsisten vacíos empíricos relevantes. En primer lugar, pocos estudios emplean la EFFR efectiva —y no el rango objetivo— para capturar las condiciones reales del mercado monetario en frecuencia mensual. En segundo lugar, es escasa la evidencia que segmenta el periodo 2018–2024 en tramos coherentes con la evolución de la política monetaria, incorporando rezagos óptimos y correcciones robustas a problemas de autocorrelación y

heterocedasticidad. Finalmente, se requiere un enfoque que combine rendimientos en exceso, diferencias logarítmicas y diagnósticos econométricos integrales para aislar los verdaderos efectos de la política monetaria sobre los mercados financieros. Este vacío es particularmente relevante para el NASDAQ-100, donde los factores tecnológicos y de productividad pueden moderar temporalmente la sensibilidad a las tasas, y para el S&P 500, cuyo carácter diversificado lo hace un termómetro más estable de la transmisión monetaria.

El problema central de esta investigación consiste en determinar cómo cambia la relación entre la EFR y los rendimientos de los índices S&P 500 y NASDAQ-100 durante los distintos regímenes económicos del periodo 2018–2024, identificando los rezagos óptimos que reflejan el horizonte de reacción de los mercados y controlando por las principales variables macroeconómicas: inflación (CPIAUCSL), desempleo (UNRATE) y producción industrial (INDPRO). Este planteamiento busca establecer si la sensibilidad del mercado a las tasas se intensifica en fases restrictivas, se atenúa durante expansiones o incluso se invierte temporalmente ante narrativas de productividad y crecimiento.

Abordar este problema requiere una metodología sólida basada en series de tiempo, con segmentación estructural por tramos (pre-COVID, COVID y post-COVID) y estimaciones por Mínimos Cuadrados Ordinarios (MCO) robustas a heterocedasticidad y autocorrelación mediante errores tipo Newey–West. Además, se aplican pruebas ADF, KPSS y ERS-DFGLS para garantizar estacionariedad, y procedimientos automáticos de selección de rezagos (AIC/BIC) para cada subperiodo. Esta estrategia permite cuantificar elasticidades diferenciadas por fase económica y comprobar si los efectos de la política monetaria sobre los activos financieros son simétricos o dependen del régimen macroeconómico vigente.

En términos prácticos, el problema es relevante porque la interpretación del ciclo reciente

ha sido ambigua: entre 2022 y 2024, los índices bursátiles registraron fuertes repuntes incluso bajo tasas de interés elevadas, lo que generó confusión sobre la eficacia del canal de transmisión monetario. Analizar si esta aparente desconexión refleja un cambio estructural en la sensibilidad de los mercados o una reconfiguración de las expectativas de riesgo y productividad constituye un aporte clave tanto para la comprensión teórica de la transmisión monetaria como para la toma de decisiones de política e inversión.

## Justificación

El estudio se justifica por la necesidad de comprender cómo la política monetaria de la Reserva Federal de Estados Unidos (Fed) influye sobre el comportamiento de los mercados bursátiles en un contexto de alta volatilidad económica. Entre 2018 y 2024, la economía estadounidense atravesó tres etapas marcadas: una fase de expansión moderada previa a la pandemia, una contracción abrupta durante la crisis sanitaria del COVID-19 y un periodo de ajuste monetario acelerado destinado a contener la inflación. Estos cambios de régimen permiten analizar de forma diferenciada la transmisión de la tasa de fondos federales (EFFR) hacia los principales índices accionarios —S&P 500 y NASDAQ-100—, los cuales capturan la dinámica tanto del mercado general como del sector tecnológico.

La relevancia del análisis radica en que los movimientos de la EFFR constituyen una de las herramientas más observadas por los inversionistas para anticipar el costo del capital, la rentabilidad esperada de los activos y la valuación de las empresas. Comprender cómo los mercados reaccionan ante modificaciones en la política monetaria resulta esencial para explicar episodios recientes de volatilidad y para identificar la sensibilidad de los precios de los activos ante distintos escenarios macroeconómicos. Además, el estudio incorpora variables reales y

nominales —inflación (CPIAUCSL), desempleo (UNRATE) y producción industrial (INDPRO)— que permiten aislar el componente estrictamente financiero de los efectos macroeconómicos estructurales.

Metodológicamente, la investigación aporta valor al combinar un enfoque de series de tiempo segmentadas con la selección automática de rezagos óptimos y el uso de varianzas robustas tipo Newey–West, lo que mejora la validez estadística frente a modelos lineales simples. Las transformaciones en log-diferencias y diferencias simples garantizan la estacionariedad de las series y facilitan la interpretación en términos de rendimientos y variaciones mensuales. Asimismo, la segmentación temporal (pre-COVID, COVID y post-COVID) permite captar la posible asimetría en la transmisión monetaria y distinguir los contextos de expansión, contracción y normalización.

En términos prácticos, los resultados ofrecen una contribución empírica y aplicada al análisis de la relación entre política monetaria y mercados financieros, aportando evidencia sobre cómo las decisiones de la Fed impactan de manera diferenciada los sectores de alta capitalización y los tecnológicos. De igual forma, proporcionan insumos útiles para inversionistas, analistas y formuladores de política, al clarificar cómo las variaciones en las tasas de interés afectan el desempeño de los activos financieros y la estabilidad macroeconómica en el corto plazo.

En suma, la justificación de este trabajo radica en su capacidad explicativa y comparativa: vincula los fundamentos teóricos de la transmisión monetaria con evidencia empírica reciente, empleando un diseño robusto, replicable y coherente con las transformaciones estructurales que caracterizaron a la economía estadounidense entre 2018 y 2024.

## Objetivos

### **Objetivo general**

Cuantificar y comparar el efecto de la Effective Federal Funds Rate (EFFR) sobre los índices S&P 500 y Nasdaq-100 durante 2019–2024, para identificar elasticidades estado-dependientes e inferir implicaciones prácticas para la toma de decisiones en mercados.

### **Objetivos específicos**

- Identificar cómo cambia la relación EFFR-mercado entre pre-pandemia, pandemia y reactivación/ajuste, precisando rezagos relevantes (corto vs. largo) y diferencias S&P 500 vs. Nasdaq-100, y traducir estos hallazgos en reglas prácticas de interpretación.
- Cuantificar y comparar las elasticidades de ambos índices frente a cambios en EFFR por tramo (modelo log-log).

## **Pregunta de Investigación**

¿Cómo impactaron los cambios en la tasa efectiva de fondos federales (EFFR) el desempeño del S&P 500 y del NASDAQ-100 entre 2019 y 2024, antes, durante y después de la pandemia?

# Alcances y limitaciones

El presente estudio analiza la relación entre la política monetaria de Estados Unidos y el comportamiento de los mercados bursátiles de gran capitalización mediante un enfoque empírico, comparativo y segmentado. El análisis abarca el período 2018–2024, lo que permite incluir tres fases macroeconómicas claramente diferenciadas: la etapa prepandemia, la disrupción económica del COVID-19 y la fase de ajuste monetario posterior. Dentro de este marco, se examinan los índices S&P 500 y NASDAQ-100, representativos del mercado accionario estadounidense, con el propósito de contrastar su sensibilidad diferencial frente a los cambios en la tasa efectiva de fondos federales (EFFR), indicador central de la postura monetaria.

El modelo incorpora además variables de control que capturan dimensiones reales y nominales de la economía: la inflación (CPIAUCSL), el desempleo (UNRATE) y la producción industrial (INDPRO). Estas variables se transforman en diferencias o log-diferencias mensuales, lo que permite trabajar con series estacionarias y estimar dinámicas coherentes con los fundamentos teóricos. El alcance del estudio se orienta a caracterizar la asociación y sensibilidad de los rendimientos bursátiles frente a variaciones en la EFFR y los factores macroeconómicos, más que a establecer una causalidad estricta. Se busca así aportar evidencia empírica sobre cómo los efectos de la política monetaria difieren entre contextos económicos y entre sectores financieros y tecnológicos, resaltando la asimetría en la transmisión de tasas durante ciclos de expansión y contracción.

Entre las principales limitaciones, se reconoce que la EFR no capta la totalidad de la postura monetaria de la Reserva Federal, al no incorporar medidas no convencionales como la reducción del balance, la guía prospectiva (*forward guidance*) o los programas de compra de activos. Asimismo, la frecuencia mensual de los datos puede generar desajustes temporales: los mercados financieros reaccionan casi en tiempo real, mientras que los indicadores macroeconómicos se publican con rezago y están sujetos a revisiones. Adicionalmente, el período 2018–2024 estuvo marcado por choques exógenos y de oferta simultáneos—incluyendo estímulos fiscales excepcionales, interrupciones en cadenas de suministro y tensiones geopolíticas— que pudieron distorsionar la relación entre tasas y precios accionarios. Finalmente, los resultados se limitan al mercado estadounidense, por lo que su generalización hacia mercados emergentes o índices sectoriales específicos debe realizarse con cautela.

En conjunto, la investigación proporciona un marco econométrico robusto y segmentado para examinar la interacción entre la política monetaria y los mercados de capitales durante un periodo de elevada volatilidad económica. La estrategia de estimación por tramos y el uso de especificaciones log-dif permiten captar cambios de régimen y mejorar la validez interna del análisis, privilegiando la comparabilidad temporal y la consistencia teórica sobre la identificación causal estricta.

# Marco teórico

La relación entre la política monetaria y los mercados bursátiles es central para comprender cómo se determinan las valoraciones, cómo se redistribuye el riesgo en la economía y por qué cambian los múltiplos cuando se modifican las condiciones financieras. En la práctica, las decisiones de la autoridad monetaria reconfiguran la tasa de descuento con la que se valoran los flujos futuros, alteran la prima de riesgo exigida por los inversionistas y condicionan la trayectoria del financiamiento para empresas y hogares. Por ello, entender cómo y cuándo la política se transmite a los índices accionarios, y por qué su efecto varía según el contexto macroeconómico y sectorial, resulta clave para interpretar episodios recientes de alta volatilidad y cambios de régimen.

En la implementación operativa, la Effective Federal Funds Rate (EFFR) funciona como el termómetro diario de la política monetaria de la Reserva Federal: sintetiza el costo del dinero a muy corto plazo entre instituciones financieras y actúa como referencia para el resto de la estructura de tasas de corto plazo, diferenciándose del rango objetivo comunicado por el FOMC. Su uso en frecuencia mensual (ya sea como promedio o fin de mes) es estándar para aproximar la postura monetaria efectiva cuando se trabaja con datos financieros y macroeconómicos de la misma periodicidad (Federal Reserve Bank of New York, s. f.). Esta elección conecta con la lógica del mecanismo de transmisión: un cambio en la tasa de corto plazo se propaga a través del sistema financiero y hacia la economía real, afectando decisiones de consumo, inversión y composición de portafolios (Ireland, 2006; Kuttner & Mosser, 2002; Bernanke & Gertler, 1999).

Para la renta variable, el canal más directo es el descuento de flujos de caja. Cuando la tasa de interés sube, aumenta la tasa de descuento y caen las valoraciones presentes; cuando baja, sucede lo contrario. Este efecto es heterogéneo porque depende de la “duración” del equity: las firmas de crecimiento, cuyos flujos relevantes se concentran en horizontes más lejanos, suelen exhibir mayor sensibilidad a variaciones en la tasa que las firmas maduras con flujos más cercanos. A nivel de índices, esa heterogeneidad se observa en diferencias de respuesta entre un referente diversificado como el S&P 500 y un índice con mayor peso tecnológico como el NASDAQ-100 (Ehrmann & Fratzscher, 2004; Bernanke & Kuttner, 2005). Además del descuento, la reacción bursátil depende de la medida en que las decisiones sorprenden respecto a lo que ya estaba incorporado en precios: los mercados descuentan con antelación movimientos plausibles, de modo que la parte no anticipada de la decisión —y la nueva información sobre la senda futura de tasas— suele concentrar el ajuste de retornos y volatilidad (Rigobon & Sack, 2004; Neuhierl & Weber, 2019).

Junto al descuento, operan mecanismos complementarios relacionados con la estructura de portafolios y con el apetito por riesgo. Cuando las condiciones monetarias comprimen los rendimientos de los activos seguros, los inversionistas tienden a rotar hacia activos de mayor riesgo, elevando temporalmente las valoraciones; cuando se normalizan las condiciones, esa compresión de primas se revierte y puede emerger un ajuste que afecte tanto precios como spreads de financiamiento. En términos de comportamiento agregado, la política no solo mueve el nivel de la tasa de descuento, sino que también influye sobre la prima exigida para mantener posiciones riesgosas. Por ello, es posible observar episodios en los que suben las tasas y, sin embargo, el mercado accionario se sostiene si la narrativa dominante descansa en ganancias de productividad, resiliencia de utilidades o una trayectoria esperada de tasas menos restrictiva que la descontada. En el extremo opuesto, la combinación de incertidumbre macro elevada y señales restrictivas explícitas puede amplificar el efecto del descuento y elevar las primas, empujando a la baja las valoraciones (Kashyap & Stein, 2023; Blinder & Reis, 2022).

La curva de rendimientos condensa la lectura del mercado sobre crecimiento e inflación y, por tanto, sobre la senda posible de la política. Una inversión prolongada de la curva suele asociarse con escenarios de desaceleración y con una preferencia más cauta por el riesgo; en esas circunstancias, la tasa de descuento relevante para valoraciones accionarias puede mantenerse elevada de forma persistente, aun sin cambios inmediatos en las utilidades. Inversamente, un proceso de desinflación creíble, acompañado por expectativas de recortes ordenados de tasas, puede aliviar la tasa de descuento y sostener múltiplos, incluso cuando el nivel de la política sigue siendo alto en términos históricos. La clave interpretativa está en distinguir entre el movimiento puntual de la tasa y el mensaje sobre su trayectoria: los mercados reaccionan al paquete completo de información, no solo al anuncio de la reunión (Campbell, Evans, Fisher & Justiniano, 2012; Miranda-Agrippino & Ricco, 2021).

Para aislar el efecto monetario de otros determinantes de precios, es estándar controlar por inflación (CPIAUCSL), holgura laboral (UNRATE) y actividad real (INDPRO). La inflación incide en costos, márgenes y credibilidad de la desinflación; el desempleo captura el pulso del mercado laboral y la presión salarial; la producción industrial aporta un indicador mensual del nivel de actividad, útil para aproximar el ciclo real. Estos controles ayudan a distinguir la porción del movimiento bursátil asociada a cambios en el factor de descuento de aquella ligada a noticias de flujos (utilidades). La evidencia sugiere, además, que la sensibilidad del mercado a la política depende del estado del ciclo y de la interacción con estos determinantes: en fases de holgura y baja inflación, sorpresas contractivas tienden a dominar la narrativa de descuento; en fases de desinflación creíble, el alivio esperado de tasas puede compensar parte del efecto negativo sobre múltiplos (Ehrmann & Fratzscher, 2004; Kuttner & Mosser, 2002; Ireland, 2006; Bernanke & Kuttner, 2005).

El análisis empírico se beneficia de segmentar la muestra en tramos coherentes con los cambios de régimen observados, en lugar de imponer una relación invariante a lo largo de todo el periodo. Cambios en el entorno —por ejemplo, tasas cercanas a cero durante una fase, seguidos de un ciclo de alzas rápidas y luego una meseta— alteran la importancia relativa de los canales descritos. En contextos de liquidez abundante, los canales de portafolio y de toma de riesgo tienden a dominar; en fases de normalización y desinflación, el canal de descuento y la revisión de utilidades cobran mayor peso. Estimar un único modelo sobre un periodo largo puede promediar realidades distintas y diluir señales, de ahí la conveniencia de trabajar por subperiodos y permitir que los rezagos se elijan con criterios de información para aproximar el horizonte al que el mercado incorpora la información monetaria (Stock & Watson, 2012; Jordà, Schularick & Taylor, 2020).

Desde la perspectiva econométrica, los niveles de índices de precios y muchas series macro son no estacionarios, por lo que es habitual modelar el comportamiento de la renta variable en log-diferencias (rendimientos) y utilizar diferencias para tasas y crecientes para variables reales. Esta estrategia alinea las series con los supuestos de los modelos lineales y reduce el riesgo de regresiones espurias. A la vez, se recomienda elegir rezagos de manera parsimoniosa, aplicar correcciones robustas a la heterocedasticidad y autocorrelación de los residuos, considerar dummies para choques extremos y vigilar la colinealidad entre controles. El objetivo no es “forzar” significancias, sino recuperar una relación estable y económicamente interpretable entre la postura monetaria efectiva y los movimientos de los índices, una vez controlados los factores macro más relevantes (Ireland, 2006; Kuttner & Mosser, 2002; Blinder & Reis, 2022).

En conjunto, la lectura teórica y empírica sugiere que el impacto de la política monetaria sobre los mercados bursátiles depende de tres piezas que interactúan constantemente: la tasa de descuento y su trayectoria esperada, la prima por riesgo y su compresión o relajación, y la evolución de los flujos esperados (utilidades). En un entorno de productividad creciente y desinflación creíble, el mercado puede sostener múltiplos a pesar de tasas aún elevadas; en un entorno de incertidumbre macro y presión de costos, el mismo nivel de tasas puede producir caídas más pronunciadas. Por eso, para interpretar adecuadamente los episodios recientes y formular hipótesis empíricas contrastables, conviene combinar una medida operativa de la postura monetaria como la EFR con controles macro, segmentación por tramos y criterios de parsimonia que permitan distinguir cambios de signo o de magnitud según el régimen dominante.

## Definiciones conceptuales y operacionales

Tabla 1

| Variable                                                     | Definición<br>Conceptual                                                                                                             | Definición<br>Operacional                                                                              | Indicador                   | Fuente | Año           |
|--------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------|-----------------------------|--------|---------------|
| <b>S&amp;P 500</b><br><b>(SP500)</b><br><b>(Dependiente)</b> | Índice bursátil<br>amplio que<br>representa el<br>desempeño de ~500<br>empresas grandes<br>listadas en EE. UU.;<br>se usa como proxy | Nivel del<br>índice bursátil<br>ajustado<br>mensualmente;<br>para la<br>estimación se<br>transforma en | Log-diferencia<br>del SP500 | FRED   | 2018-<br>2024 |

|                                                 |                                                                                                                        |                                                                                                                                                                             |                           |      |           |
|-------------------------------------------------|------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------|------|-----------|
|                                                 | del mercado accionario estadounidense.                                                                                 | logaritmos naturales y se utiliza su diferencia logarítmica ( $\Delta \ln$ ) para representar el rendimiento mensual.                                                       |                           |      |           |
| <b>NASDAQ-100 (NDX)</b><br><i>(Dependiente)</i> | Índice que agrupa a ~100 empresas no financieras listadas en NASDAQ, con alta ponderación en tecnología y crecimiento. | Nivel mensual del índice transformado a logaritmos naturales; se utiliza su diferencia logarítmica ( $\Delta \ln$ ) como medida del retorno mensual del sector tecnológico. | Log-diferencia NASDAQ-100 | FRED | 2018-2024 |

|                                                   |                                                                                                                                                                 |                                                                                                                                                                                                                              |                             |      |           |
|---------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------|------|-----------|
| <b>Tasa efectiva de fondos federales (EFFR)</b>   | Tasa de interés a un día a la que las instituciones depositarias negocian saldos de reservas; instrumento operativo central de la política monetaria de la FED. | Serie mensual expresada en porcentaje; se emplea la diferencia simple ( $\Delta$ EFFR) para capturar cambios mensuales en la política monetaria. Se incluyen rezagos y dummies por régimen monetario (ZLB, hiking, plateau). | Diferencia de la EFFR       | FRED | 2018-2024 |
| <b>Índice de Precios al Consumidor (CPIAUCSL)</b> | Medida del nivel general de precios al consumidor para la población urbana en                                                                                   | Serie mensual indexada (Base 1982–84=100); se                                                                                                                                                                                | Log-diferencia del CPIAUCSL | FRED | 2018-2024 |

|                                           |                                                                                                                                                          |                                                                                                                                                                                                    |                            |      |               |
|-------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------|------|---------------|
|                                           | EE. UU.<br>(desestacionalizada).                                                                                                                         | transforma en<br>logaritmos<br>naturales y se<br>utiliza su<br>diferencia<br>logarítmica<br>( $\Delta \ln$ ) como<br>proxy de la<br>tasa de<br>inflación<br>mensual.                               |                            |      |               |
| <b>Tasa de<br/>desempleo<br/>(UNRATE)</b> | Porcentaje de la<br>fuerza laboral sin<br>empleo y buscando<br>activamente trabajo;<br>proxy del ciclo<br>económico y<br>holgura del mercado<br>laboral. | Serie mensual<br>expresada en<br>porcentaje; se<br>utiliza su<br>diferencia<br>simple<br>( $\Delta \text{UNRATE}$ )<br>para capturar<br>variaciones en<br>el desempleo y<br>su efecto sobre<br>los | Diferencia de la<br>UNRATE | FRED | 2018-<br>2024 |

|                                             |                                                                                                                                                |                                                                                                                                                                                                        |                           |      |           |
|---------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------|------|-----------|
|                                             |                                                                                                                                                | rendimientos financieros.                                                                                                                                                                              |                           |      |           |
| <b>Industrial Production Index (INDPRO)</b> | Mide el nivel de producción real de los sectores industriales, incluyendo manufactura, minería y servicios públicos (electricidad, gas y agua) | Serie mensual indexada (Base 2017=100); se transforma en logaritmos naturales y se utiliza su diferencia logarítmica ( $\Delta \ln$ ) como medida del crecimiento de la producción industrial mensual. | Log-diferencia del INDPRO | FRED | 2018-2024 |

*Nota: Elaboración propia con información de la FRED.*

# Metodología

## Tipo y diseño de investigación

Nuestro estudio se enmarca en un enfoque cuantitativo y adopta un alcance correlacional-explicativo. Es correlacional porque se examina la relación estadística entre la política monetaria de la Reserva Federal (EFFR) y el comportamiento de los mercados accionarios estadounidenses —representados por el S&P 500 y el NASDAQ-100—, controlando por inflación (CPIAUCSL), desempleo (UNRATE) y producción industrial (INDPRO). Es explicativo porque, además de medir la dirección y magnitud de las asociaciones, se contrastan mecanismos causales plausibles (canal de tasas de interés, costo de capital, prima por riesgo y respuesta cíclica real) con evidencia empírica mensual para el periodo 2018–2024, que abarca tres etapas económicas diferenciadas: pre-pandemia, pandemia y post-pandemia.

El diseño de investigación es no experimental y observacional, de tipo longitudinal retrospectivo, pues utiliza información secundaria de fuentes oficiales y reproducibles (FRED, BLS y proveedores de índices financieros). La unidad de análisis corresponde a la trayectoria temporal de cada serie macroeconómica y financiera, lo que permite estudiar la dinámica conjunta entre política monetaria y desempeño bursátil sin manipular variables.

Metodológicamente, implementamos un diseño segmentado de series de tiempo, en el que se identifican quiebres estructurales y se dividen las observaciones en tres tramos: Pre-COVID (2018-01 a 2020-02), COVID-Recovery (2020-03 a 2021-12) y Post-Hiking (2022-01 a 2024-12). En cada segmento se estiman modelos AR/ADL multivariados con rezagos óptimos seleccionados mediante el criterio BIC, permitiendo capturar los efectos dinámicos de la EFFR

sobre los retornos bursátiles y los canales de transmisión real. Todas las series se transforman para asegurar estacionariedad: se aplican diferencias logarítmicas para los índices (retornos) e incrementos simples para tasas y variables reales, validadas mediante las pruebas ADF, KPSS y ERS-DFGLS.

La estimación se realiza mediante Mínimos Cuadrados Ordinarios (MCO) con errores robustos de Newey-West, corrigiendo por heterocedasticidad y autocorrelación serial, e incorporando variables rezagadas e interacciones por régimen monetario (ZLB, hiking y plateau). Se implementan además dummies de choque (marzo-abril 2020) y winsorización al 1 % para mitigar la influencia de outliers extremos. Los diagnósticos complementarios incluyen pruebas Breusch-Godfrey, Breusch-Pagan/White, RESET, Jarque-Bera, VIF y CUSUM/MOSUM para evaluar autocorrelación, homocedasticidad, especificación funcional, normalidad, colinealidad y estabilidad de parámetros.

En síntesis, se trata de una investigación cuantitativa, correlacional-explicativa, con un diseño no experimental de series temporales segmentadas, que combina técnicas de cointegración, diferenciación y modelado dinámico con inferencia robusta. Este enfoque permite explicar empíricamente cómo las variaciones de la EFFR afectan los rendimientos de los índices NASDAQ-100 y S&P 500, controlando por los determinantes macroeconómicos clave y comparando la magnitud del impacto antes, durante y después de la pandemia, bajo distintos regímenes de política monetaria.

## Especificación de los modelos econométricos

Con el fin de explicitar los modelos utilizados y la relación entre la variable dependiente

y las independientes, se trabaja con retornos en exceso de cada índice bursátil respecto a la tasa libre de riesgo aproximada por la EFFR mensual. Para cada mes  $t$ :

- $R_t^{SP} = \text{Rex\_SP500}_t = \Delta \ln(\text{SP500}_t) - rf_t$
- $R_t^{NAS} = \text{Rex\_NASDAQ}_t = \Delta \ln(\text{NASDAQ100}_t) - rf_t$

donde  $rf_t = \text{EFFR}_t/100/12$  es la tasa de fondos federales mensualizada en términos decimales, y  $\Delta \ln(\cdot)$  denota diferencia logarítmica.

Las variables explicativas se construyen como transformaciones estacionarias de las series originales:

- $\Delta \text{EFFR}_t^{BASE} = d\_EFFR\_BASE_t$ : cambio de la EFFR fuera de los regímenes especiales (régimen base).
- $\Delta \text{EFFR}_t^{ZLB} = d\_EFFR\_ZLB_t$ : cambio de la EFFR cuando la tasa se encuentra en el zero lower bound (ZLB), característico del tramo COVID.
- $\Delta \text{EFFR}_t^{HIK} = d\_EFFR\_HIKING_t$ : cambio de la EFFR durante la fase de alzas (ciclo de subidas a partir de 2022).
- $\Delta \text{EFFR}_t^{PLA} = d\_EFFR\_PLATEAU_t$ : cambio de la EFFR durante la fase de meseta (“plateau”) de tasas altas.
- $\pi_t = \Delta \ln(\text{CPIAUCSL}_t) = d\log\_CPIAUCSL_t$ : inflación mensual.
- $g_t = \Delta \ln(\text{INDPRO}_t) = d\log\_INDPRO_t$ : crecimiento mensual de la producción industrial.
- $u_t = \Delta \text{UNRATE}_t = d\_UNRATE_t$ : cambio mensual de la tasa de desempleo.
- $D_{Mar20,t} = D\_2020m03_t$  y  $D_{Abr20,t} = D\_2020m04_t$ : dummies que capturan los choques extremos de marzo y abril de 2020.

En la implementación computacional, los cambios de la EFR por régimen ( $\Delta EFR_t^{BASE}, \Delta EFR_t^{ZLB}, \Delta EFR_t^{HIK}, \Delta EFR_t^{PLA}$ ) se construyen como interacciones entre  $\Delta EFR_t$  y dummies de régimen, y se permite que entren con rezagos  $\ell \in \{0,1,2\}$  seleccionados automáticamente mediante el criterio BIC. De forma análoga, la inflación  $\pi_t$ , la producción industrial  $g_t$  y el desempleo  $u_t$  se incorporan con rezagos óptimos  $\ell$  en cada segmento.

Sobre esta base, los seis modelos estimados (dos por segmento y por índice) se pueden expresar de manera esquemática como:

**a) Segmento PRE (2018-01 a 2020-02)**

- Modelo PRE – S&P 500

$$R_t^{SP} = \alpha_1 + \beta_1 \Delta EFR_{t-\ell_1}^{BASE} + \beta_2 \pi_{t-\ell_2} + \beta_3 g_{t-\ell_3} + \beta_4 u_{t-\ell_4} + \varepsilon_t^{PRE,SP}$$

- Modelo PRE – NASDAQ-100

$$R_t^{NAS} = \alpha_2 + \gamma_1 \Delta EFR_{t-\ell_1}^{BASE} + \gamma_2 \pi_{t-\ell_2} + \gamma_3 g_{t-\ell_3} + \gamma_4 u_{t-\ell_4} + \varepsilon_t^{PRE,NAS}$$

En este tramo los modelos PRE no incluyen término autorregresivo ni dummies, de acuerdo con la selección BIC.

**b) Segmento COVID / ZLB (2020-03 a 2021-12)**

- Modelo COVID – S&P 500

$$R_t^{SP} = \alpha_3 + \delta_1 \Delta EFR_{t-\ell_1}^{ZLB} + \delta_2 \pi_{t-\ell_2} + \delta_3 g_{t-\ell_3} + \delta_4 u_{t-\ell_4} + \delta_5 R_{t-1}^{SP} + \varepsilon_t^{COV,SP}$$

Este modelo incorpora un término autorregresivo  $R_{t-1}^{SP}$ , en línea con la especificación AR(1) seleccionada por el algoritmo ADL-BIC para el S&P 500 en el tramo COVID.

- Modelo COVID – NASDAQ-100

$$R_t^{NAS} = \alpha_4 + \theta_1 \Delta EFR_{t-\ell_1}^{ZLB} + \theta_2 \pi_{t-\ell_2} + \theta_3 g_{t-\ell_3} + \theta_4 u_{t-\ell_4} + \theta_5 D_{Abr20,t} + \varepsilon_t^{COV,NAS}$$

En este caso, el modelo para el NASDAQ-100 durante COVID no incluye término AR(1), pero sí retiene la dummy de abril de 2020 ( $D_{Abr20,t}$ ), que concentra buena parte del rebote extraordinario posterior al shock inicial.

### c) Segmento POST (2022-01 a 2024-12)

- Modelo POST – S&P 500

$$R_t^{SP} = \alpha_5 + \phi_1 \Delta EFR_{t-\ell_1}^{HIK} + \phi_2 \Delta EFR_{t-\ell_2}^{PLA} + \phi_3 \pi_{t-\ell_3} + \phi_4 g_{t-\ell_4} + \phi_5 u_{t-\ell_5} + \varepsilon_t^{POST,SP}$$

- Modelo POST – NASDAQ-100

$$R_t^{NAS} = \alpha_6 + \eta_1 \Delta EFR_{t-\ell_1}^{HIK} + \eta_2 \Delta EFR_{t-\ell_2}^{PLA} + \eta_3 \pi_{t-\ell_3} + \eta_4 g_{t-\ell_4} + \eta_5 u_{t-\ell_5} + \varepsilon_t^{POST,NAS}$$

En el segmento POST, tanto para S&P 500 como para NASDAQ-100, la especificación seleccionada incluye los cambios de la EFR diferenciados por fase del ciclo (alzas y meseta), junto con inflación, producción industrial y desempleo rezagados, sin términos AR(1) ni dummies adicionales.

En todos los casos, la estimación se realiza mediante MCO con errores robustos de Newey–West, y los shocks monetarios por régimen ( $\Delta EFR$ ) se construyen como interacciones de  $\Delta EFR_t$  con los dummies de régimen, permitiendo además su ortogonalización respecto a las variables reales ( $\pi_t, g_t, u_t$ ) para aislar el componente puramente monetario. Los valores puntuales de los parámetros, sus signos, significancia estadística y la interpretación económica detallada de cada coeficiente se presentan en la sección de resultados.

## Técnicas e instrumentos de recolección de datos

Para el desarrollo del presente estudio se utilizó información secundaria proveniente de un repositorio oficial y académico de series macroeconómicas y financieras, garantizando la consistencia en definiciones, periodicidad y unidades. Se armonizaron las series para el periodo 2018–2024 mediante depuración de valores faltantes, alineación temporal y construcción de rezagos. Se consideraron los siguientes insumos:

- **S&P 500 (SP500) (FRED):** Índice amplio del mercado accionario de Estados Unidos. Se emplea como variable dependiente para capturar el desempeño bursátil agregado.
- **NASDAQ-100 (NASDAQ100) (FRED):** Índice de empresas de gran capitalización con énfasis en tecnología. Se usa como variable dependiente alternativa para contrastar sensibilidad sectorial.
- **Tasa efectiva de fondos federales (EFFR) (FRED):** Medida operativa de la postura de política monetaria. Actúa como variable explicativa principal, modelada con rezagos y en especificación log–log.
- **Índice de precios al consumidor: All Urban Consumers (CPIAUCSL) (FRED):** Indicador agregado de inflación. Se incorpora como variable de control para aislar presiones de precios sobre los rendimientos bursátiles.
- **Tasa de desempleo (UNRATE) (FRED):** Medida del ciclo laboral y la holgura de la economía. Se incluye como variable de control rezagada.
- **Índice de producción industrial (INDPRO) (FRED):** Indicador del nivel de producción real de los sectores industriales, incluyendo manufactura, minería y servicios públicos (electricidad, gas y agua)

## Información previa

Gráficos de tendencias de patrones.

### Vista general del Nasdaq100 y SP&500 con la EFR.



*Nota: Grafica tomada de trading view*


La figura muestra la evolución conjunta de los índices NASDAQ100 y S&P500 (líneas azul y roja, respectivamente) frente a la tasa de fondos federales (EFFR) (línea púrpura) entre 2018 y 2024. Se observa una tendencia ascendente pronunciada en ambos índices bursátiles hasta comienzos de 2022, impulsada por las políticas monetarias expansivas y los bajos niveles de tasas de interés implementados tras la crisis de 2020. Durante ese periodo, la EFFR permaneció cercana a cero, lo que facilitó condiciones financieras favorables, incrementando la valorización de los activos de renta variable, especialmente en el sector tecnológico representado por el NASDAQ100.

A partir de 2022, la Reserva Federal inició un ciclo acelerado de aumentos en la tasa de interés, llevando la EFFR desde niveles cercanos a 0 % hasta más del 5 % en 2023. Este endurecimiento monetario generó una corrección temporal en los mercados bursátiles, visible en la caída de ambos índices durante ese año. Sin embargo, hacia 2024 se aprecia una recuperación parcial, señalando que los inversionistas ajustaron sus expectativas frente a un escenario de estabilización

monetaria. En conjunto, el gráfico ilustra claramente la relación inversa entre política monetaria restrictiva y desempeño de los mercados financieros, donde el incremento de las tasas reduce la liquidez y la valoración de los activos, mientras que las fases de tasas bajas impulsan el crecimiento de los índices.

### Vista general de las variables de control por años

Grafico 1



*Elaboración propia en R con datos de la FRED.*

La figura muestra la evolución individual de la tasa de fondos federales (EFFR), el índice de producción industrial (INDPRO) y el índice de precios al consumidor (CPIAUCSL) para el periodo 2018–2024. Se observa que la EFFR se mantuvo estable y cercana a cero entre 2020 y comienzos de 2022, en respuesta a la política monetaria expansiva implementada por la Reserva Federal para mitigar los efectos económicos de la pandemia. A partir de 2022, la autoridad monetaria inició un ciclo de aumentos sucesivos en las tasas de interés, alcanzando niveles superiores al 5 % en 2023, con el objetivo de contener las presiones inflacionarias derivadas de

la rápida recuperación económica y el incremento de los precios.

En cuanto a las variables reales, el índice de producción industrial (INDPRO) evidencia una caída abrupta durante 2020, coincidente con las restricciones sanitarias y la desaceleración global, seguida de una recuperación progresiva hasta estabilizarse en niveles similares a los previos a la pandemia. Por su parte, el índice de precios al consumidor (CPIAUCSL) muestra una tendencia ascendente constante, con una aceleración marcada a partir de 2021, reflejando el repunte inflacionario posterior a la crisis sanitaria. En conjunto, los gráficos permiten visualizar la interacción entre política monetaria, actividad económica e inflación, destacando cómo la subida de tasas (EFFR) respondió al incremento sostenido de precios y al dinamismo de la producción industrial en la fase de recuperación económica.

## Estadística descriptiva

**Media, desviación, Máximos y Mínimos**

**Tabla 2**

Estadísticos descriptivos de las variables del modelo

| <b>Variable</b>   | <b>Media</b> | <b>Desviación<br/>estándar</b> | <b>Mínimo</b> | <b>Máximo</b> |
|-------------------|--------------|--------------------------------|---------------|---------------|
| <b>SP500</b>      | 38505.90     | 3850.590                       | 2567.310      | 6010.910      |
| <b>NASDAQ-100</b> | 12198.63     | 4131.552                       | 4131.552      | 21493.35      |

|               |         |        |          |          |
|---------------|---------|--------|----------|----------|
|               |         |        |          |          |
| <b>CPI</b>    | 278.229 | 23.810 | 2488.590 | 317.6030 |
| <b>INDPRO</b> | 101.165 | 3.453  | 84.681   | 104.103  |
| <b>UNRATE</b> | 4.619   | 2.052  | 3.400    | 14.800   |
| <b>EFFR</b>   | 2.327   | 1.991  | 0.050    | 5.330    |

*Nota: Elaboración propia con base en información de la FRED. Cálculos realizados con R Studio.*

La tabla 3.1 muestra los estadísticos descriptivos de las variables utilizadas en el modelo. Se observa que los índices bursátiles (NASDAQ-100 y S&P500) presentan los valores promedio más altos y también la mayor dispersión, reflejando una alta volatilidad en los mercados financieros durante el periodo 2018–2024. En contraste, las variables macroeconómicas como INDPRO y CPI exhiben menor variabilidad, indicando una evolución más estable en la producción industrial y los precios.

Por su parte, las tasas de desempleo (UNRATE) y de interés de la FED (EFFR) muestran promedios bajos, con una desviación moderada, lo que evidencia que, aunque hubo aumentos puntuales (como durante la pandemia o los ajustes monetarios recientes), su comportamiento general fue relativamente controlado. En conjunto, la tabla refleja un entorno de alta sensibilidad financiera frente a cambios económicos y de política monetaria.

**Tabla 3**  
**Curtosis y errores estándar**

| <b>Variable</b>   | <b>Curtosis</b> | <b>Error estándar</b> |
|-------------------|-----------------|-----------------------|
| <b>EFFR</b>       | -1.37           | 0.22                  |
| <b>UNRATE</b>     | 9.89            | 0.22                  |
| <b>INDPRO</b>     | 8.77            | 0.38                  |
| <b>CPIAUCLS</b>   | -1.58           | 2.60                  |
| <b>NASDAQ100</b>  | -0.94           | 450.79                |
| <b>SP&amp;500</b> | -0.76           | 100.41                |

*Elaboración propia en R con datos de la FRED.*


Los resultados de curtosis muestran diferencias notables entre las variables macroeconómicas y las financieras. Las variables UNRATE (9.89) e INDPRO (8.77) presentan valores de curtosis positivos y elevados, lo que indica una distribución leptocúrtica, con colas más pesadas y mayor concentración en torno a la media. Esto sugiere que ambas variables experimentaron episodios extremos o atípicos, especialmente durante periodos de choques económicos como la pandemia o los ajustes propios del ciclo económico estadounidense.

Por el contrario, las variables EFFR (-1.37), CPIAUCSL (-1.58), NASDAQ100 (-0.94) y SP500 (-0.76) muestran valores negativos o cercanos a cero, característicos de distribuciones platicúrticas, con menor concentración alrededor de la media y colas más ligeras. En el caso de las variables financieras, esto refleja una mayor estabilidad relativa en los niveles de los índices, mientras que en el contexto macroeconómico sugiere dinámicas más suaves en la tasa de interés y los precios. En conjunto, las diferencias entre curtosis macro y financiera evidencian que los

mercados bursátiles tienden a ajustes graduales, mientras que las variables reales son más sensibles a los cambios abruptos del entorno económico y la política monetaria.

### Grafico de Boxplot

Grafico 2



*Elaboración propia en R con datos de la FRED*

La figura muestra los diagramas de caja (boxplots) de las variables incluidas en el modelo, los cuales permiten observar su dispersión y la presencia de valores atípicos. En términos generales, las variables financieras NASDAQ100 y SP500 mantienen una distribución relativamente simétrica y compacta, sin presencia significativa de outliers. Esto indica una evolución estable de los índices bursátiles en el periodo analizado, pese a las fluctuaciones de mercado.

Por el contrario, las variables macroeconómicas UNRATE e INDPRO evidencian


múltiples valores atípicos, reflejando choques abruptos en la tasa de desempleo y en la producción industrial, coherentes con los efectos de la pandemia del 2020 y los procesos posteriores de recuperación. En cambio, EFR y CPIAUCSL muestran distribuciones más concentradas y estables, lo que sugiere una menor volatilidad relativa en las tasas de interés y en el nivel de precios al consumidor. En conjunto, los boxplots destacan la mayor sensibilidad de las variables reales ante los ciclos económicos, frente a la estabilidad relativa del sector financiero, donde los movimientos son más graduales y menos propensos a valores extremos.

### Gráfico o matriz de correlación

Gráfico 3

Matriz de correlación de las variables del modelo

#### Matriz de Correlación de las Variables del Modelo



*Nota: Elaboración propia con datos de la FRED en rstudio.*

La matriz de correlación evidencia relaciones coherentes con la teoría económica entre las variables del modelo. Se observa una correlación positiva muy alta entre NASDAQ100 y SP500 ( $r \approx 0.99$ ), lo que confirma que ambos índices bursátiles se mueven casi en sincronía,


reflejando la evolución conjunta de los mercados financieros estadounidenses. Asimismo, la variable CPIAUCSL muestra una correlación positiva fuerte con EFR (r  $\approx$  0.73), lo que indica que los aumentos en la tasa de interés suelen estar asociados con incrementos en el nivel general de precios, especialmente en periodos donde la Reserva Federal adopta posturas contractivas para controlar la inflación.

Por otro lado, se aprecia una correlación negativa muy fuerte entre UNRATE e INDPRO (r  $\approx$  -0.96), lo que confirma la relación inversa clásica entre desempleo y producción industrial: cuando la actividad económica se expande, el desempleo tiende a reducirse. Además, la correlación moderada entre EFR y los índices bursátiles ( $\approx$  0.45–0.48) sugiere que los cambios en la política monetaria impactan en los mercados financieros, aunque no de manera inmediata ni perfectamente lineal. En conjunto, la matriz refleja la interdependencia entre las variables macroeconómicas y financieras, donde las variables reales —especialmente el desempleo y la producción— representan los vínculos estructurales del modelo, mientras que las financieras responden con mayor rezago a los ajustes de política monetaria y condiciones macroeconómicas.

## Resultados

### 4.1. Visualización inicial

Gráfico 4




*Elaboración propia en R con datos de FRED*

### Índices (SP500 y NASDAQ-100).

Entre 2018 y comienzos de 2020 ambos índices muestran una tendencia alcista moderada, interrumpida por la caída abrupta de marzo-abril de 2020. Desde mediados de 2020 se observa una recuperación vigorosa que culmina en máximos a fines de 2021 (más marcado en el NASDAQ-100), seguida por un retroceso durante 2022 consistente con el giro contractivo de la política monetaria. Desde 2023 se retoma una senda ascendente, con nuevas cotas históricas hacia finales de 2024. La amplitud de los movimientos es mayor en el NASDAQ-100, coherente con su mayor duración y peso tecnológico.

Gráfico 5



*Elaboración propia en R con datos de FRED*

### **Inflación (CPIAUCSL).**

El nivel del CPI es prácticamente monótono: ascenso tenue 2018–2020, aceleración visible durante 2021–2022 y normalización paulatina desde 2023, sin caídas en nivel. Este perfil anticipa que, en niveles, la serie será no estacionaria y requerirá trabajar con tasas de variación (log-diferencias) para el análisis econométrico.

### **Actividad real (INDPRO).**

La producción industrial muestra estabilidad previa al choque COVID, colapso súbito en marzo-abril de 2020 y una recuperación en forma de “V” que converge hacia su banda pre-pandemia entre 2021 y 2022. Desde entonces oscila en un rango estrecho, sin tendencia definida, lo que sugiere ciclos de corta duración alrededor de un nivel.

### **Política monetaria (EFR).**

La serie muestra tres etapas claras: (i) 2018–2019 con una normalización gradual de la tasa; (ii) 2020–2021 con valores de la tasa excepcionalmente bajos durante un periodo prolongado; y (iii) desde marzo de 2022 un ciclo de incrementos rápidos que lleva la tasa a niveles altos, seguido en 2023–2024 por varios meses de estabilidad y una leve corrección a la baja hacia el cierre de la muestra. Este patrón temporal aporta un telón de fondo útil para leer las oscilaciones de los índices y de las variables reales en los apartados siguientes.

### **Mercado laboral (UNRATE).**

La tasa de desempleo se mantiene baja y estable hasta inicios de 2020, exhibe un pico extraordinario en abril-mayo de 2020 y desciende de manera sostenida hasta mínimos alrededor de 2022–2023. A lo largo de 2024 aparece una leve re-aceleración hacia ~4 %, consistente con una desaceleración suave del mercado laboral.

## **4.2. Pruebas de raíz unitaria en nivel (ADF)**

S&P 500 (nivel, tendencia,  $k=9$ ). El ADF con tendencia reporta  $\tau \approx -1.503$  (crítico 5%:  $-3.45$ ), muy lejos en valor absoluto del umbral; el contraste auxiliar con el mismo  $k$  confirma el no rechazo de raíz unitaria ( $DF = -2.5976$ ;  $p=0.3307$ ). Lectura: el nivel del S&P 500 es no estacionario en la muestra; se trabajará con retornos logarítmicos.

NASDAQ-100 (nivel, tendencia,  $k=9$ ). El ADF entrega  $\tau \approx -1.3819$  (5%:  $-3.45$ ), sin evidencia de estacionariedad en nivel; el `adf.test` con igual  $k$  respalda el no rechazo ( $DF = -2.4038$ ;  $p=0.4103$ ). Conclusión: el nivel del NASDAQ-100 es no estacionario; se usarán retornos logarítmicos.

CPIAUCSL (nivel, tendencia,  $k=9$ ). El ADF con tendencia arroja  $\tau \approx -2.1043$ , por encima

(en valor absoluto) del umbral del 10% ( $-3.15$ ), por lo que no se rechaza raíz unitaria; el  $\text{adf.test}$  coincide ( $\text{DF}=-2.7738$ ;  $p=0.2585$ ). Implicación: el nivel del CPI es no estacionario; modelaremos crecimientos logarítmicos.

INDPRO (nivel, drift,  $k=9$ ). El ADF con drift muestra  $\tau \approx -3.0211$ , que sí supera el umbral al 5% ( $-2.89$ ); sin embargo, el  $\text{adf.test}$  con el mismo  $k$  no lo confirma ( $\text{DF}=-1.9721$ ;  $p=0.5873$ ). Dada la discrepancia entre especificaciones, adoptamos un criterio conservador: tratamos INDPRO como no estacionario en nivel y utilizamos  $\text{dlog}(\text{INDPRO})$ .

UNRATE (nivel, drift,  $k=9$ ). El ADF entrega  $\tau \approx -2.8259$ , compatible a lo sumo con rechazo al 10% ( $-2.58$ ) pero no al 5% ( $-2.89$ ); el  $\text{adf.test}$  tampoco rechaza ( $\text{DF}=-2.1232$ ;  $p=0.5254$ ). Conclusión: UNRATE en nivel es no estacionario; se trabajará con primeras diferencias.

EFFR (nivel, drift,  $k=9$ ). El ADF muestra  $\tau \approx -0.8938$ , muy lejos del crítico ( $-2.89$  al 5%), y el  $\text{adf.test}$  mantiene el no rechazo ( $\text{DF}=-2.4897$ ;  $p=0.3750$ ). Interpretación: EFFR en nivel es no estacionaria; modelaremos primeras diferencias para capturar shocks de tasa.

#### 4.3. Transformaciones estacionarias (lag=1)

Tabla 4

| variable      | n_obs | n_na |
|---------------|-------|------|
| dlog_SP500    | 83    | 0    |
| dlog_NASDAQ   | 83    | 0    |
| dlog_CPIAUCSL | 83    | 0    |

|             |    |   |
|-------------|----|---|
| dlog_INDPRO | 83 | 0 |
| d_EFFR      | 83 | 0 |
| d_UNRATE    | 83 | 0 |

Con base en los ADF en nivel—que no rechazaron raíz unitaria para S&P 500, NASDAQ-100, CPI y EFFR; mostraron evidencia, a lo sumo, marginal para UNRATE; y un resultado mixto para INDPRO ( $\tau \approx -3.02$  con drift, pero sin confirmación en el contraste alterno)—se construyeron transformaciones estacionarias de primer orden con lag=1: retornos logarítmicos dlog\_SP500 y dlog\_NASDAQ, crecimientos dlog\_CPIAUCSL e dlog\_INDPRO, y diferencias d\_EFFR y d\_UNRATE. Las seis variables quedaron disponibles en Base\_tr1; el NA inicial esperado por el operador diff se eliminó con slice(-1), y la verificación arrojó **0 NA** en cada serie (n=83), por lo que la muestra efectiva se mantiene íntegra para la modelación posterior.

#### 4.4. Estacionariedad de transformaciones

A partir de las series transformadas en el paso anterior (retornos logarítmicos para SP500 y NASDAQ; crecimientos logarítmicos para CPI e INDPRO; primeras diferencias para EFFR y UNRATE), se contrastó estacionariedad con tres familias de pruebas estándar: (i) ADF con selección automática de rezagos por BIC y determinístico acorde a la naturaleza de cada variable (retornos: *type=none*; macro y tasas: *drift*), (ii) KPSS en nivel ( $H_0$ : estacionariedad) y (iii) ERS/DF-GLS con constante. Todas las pruebas se corrieron sobre la muestra post-*slice* (lag=1),

con  $k=9$  como máximo efectivo en los ADF auto. La interpretación combina señales: ADF para descartar raíz unitaria, KPSS para no rechazar estacionariedad en nivel y DF-GLS como contraste más exigente y robusto a correlación serial.

**dlog\_SP500.** El ADF (*none*) rechaza raíz unitaria de forma holgada ( $\tau \approx -5.87 < \text{c.v. } 1\% = -2.60$ ), el KPSS no rechaza estacionariedad ( $p \approx 0.10$ ) y el DF-GLS es conservador y no rechaza al 10% ( $\approx -0.75 > -1.62$ ). Interpretación: evidencia suficiente para tratar el retorno del SP500 como estacionario, con la salvedad de que DF-GLS es más estricto.

**dlog\_NASDAQ.** El ADF (*none*) rechaza con amplitud ( $\tau \approx -5.33 < -2.60$ ), el KPSS no rechaza ( $p \approx 0.10$ ) y el DF-GLS no rechaza al 10% ( $\approx -1.52 > -1.62$ ). Interpretación: análogo a SP500; se modela como estacionaria, manteniendo nota de prudencia por DF-GLS.

**dlog\_CPIAUCSL.** El ADF (*drift*) rechaza a 5% ( $\tau \approx -3.05 < -2.89$ ); el KPSS queda cercano al umbral pero no rechaza ( $p \approx 0.073$ ) y el DF-GLS no rechaza ( $\approx -1.43 > -1.62$ ). Interpretación: se considera estacionaria para ADL, con advertencia por el KPSS relativamente alto y el DF-GLS exigente.

**dlog\_INDPRO.** El ADF (*drift*) rechaza de forma contundente ( $\tau \approx -7.52 < -3.51$ ), el KPSS no rechaza ( $p \approx 0.10$ ) y el DF-GLS confirma ( $\approx -2.61 < -1.94$ ). Interpretación: estacionaria sin reservas; señal consistente en las tres pruebas.

**d\_EFFR.** El ADF (*drift*) resulta marginal/no concluyente ( $\tau \approx -2.15 > -2.58$ ), pero el KPSS no rechaza ( $p \approx 0.10$ ) y el DF-GLS sí rechaza a 5% ( $\approx -2.07 < -1.94$ ). Interpretación: la combinación KPSS+DF-GLS avala estacionariedad de la primera diferencia de la tasa de fondos federales.

**d\_UNRATE.** El ADF (*drift*) rechaza en 1% ( $\tau \approx -6.77 < -3.51$ ), el KPSS no rechaza

( $p \approx 0.10$ ) y el DF-GLS confirma en 1% ( $\approx -3.29 < -2.59$ ). Interpretación: estacionaria de forma clara y consistente.

Los retornos bursátiles ( $dlog\_SP500$ ,  $dlog\_NASDAQ$ ), los crecimientos de actividad e inflación ( $dlog\_INDPRO$ ,  $dlog\_CPIAUCSL$ ) y las primeras diferencias de tasas y desempleo ( $d\_EFFR$ ,  $d\_UNRATE$ ) presentan, en conjunto, evidencia suficiente de estacionariedad para proceder con los modelos ADL. Se dejan dos salvedades para verificación de robustez en los diagnósticos: (i) DF-GLS más exigente en los retornos y (ii) el KPSS relativamente alto en  $dlog\_CPIAUCSL$ .

#### 4.4. Regímenes monetarios

Para aislar cómo cambia el canal de transmisión monetaria según el contexto, dividimos la muestra en tres regímenes exógenos por calendario: ZLB/COVID (mar-2020–dic-2021), HIKING (mar-2022–jul-2023) y PLATEAU (ago-2023–dic-2024); todo lo demás es BASELINE. La lógica es sencilla: cuando la tasa está pegada al piso (ZLB), cuando la FED está subiendo activamente (HIKING) y cuando mantiene una meseta (PLATEAU), el mismo movimiento de  $\Delta EFFR$  no debería “pegar” igual sobre retornos y variables reales. Con esta partición, interactuamos el shock monetario mensual con cada régimen — $d\_EFFR\_ZLB$ ,  $d\_EFFR\_HIKING$ ,  $d\_EFFR\_PLATEAU$ — y añadimos  $L1\_d\_EFFR$  como control dinámico mínimo. El conteo muestral quedó en ZLB/COVID = 22 | HIKING = 17 | PLATEAU = 17 | BASELINE = 27.

En los ADL siguientes, estas interacciones cumplen dos roles claros. (i) Identificación de

estado-dependencia: los coeficientes de  $d\_EFFR\_*$  son semi-elasticidades específicas de régimen; compararlos permite ver si el mercado y la actividad reaccionan más (o menos) en ZLB, en alzas o en meseta frente al baseline. (ii) Parsimonia con interpretación económica: en lugar de estimar modelos separados por submuestras, un único modelo recoge las diferencias estructurales mediante dummies por régimen multiplicadas por  $\Delta EFFR$ , manteniendo la comparabilidad y evitando pérdida innecesaria de grados de libertad. En resumen, hacemos esto para permitir que la “potencia” del shock monetario varíe con el entorno de política y para medir explícitamente si la respuesta financiera y real es más fuerte en fases de alzas, se amortigua en meseta o se distorsiona cerca del piso efectivo.

#### 4.5. Segmentación PRE/COVID/POST

[Segmentación] PRE=25 | COVID=22 | POST=36]



Nota: Grafica tomada de trading view

La segmentación PRE (ene-2018–feb-2020;  $n=25$ ), COVID (mar-2020–dic-2021;  $n=22$ ) y POST (ene-2022–dic-2024;  $n=36$ ) obedece a rupturas macro-financieras y de política monetaria objetivamente identificables, no a cortes ad hoc. El punto de quiebre en marzo de 2020 coincide con el shock pandémico global que alteró simultáneamente: la función de pérdida social y las restricciones de oferta/demanda; el régimen de política (tasa en el piso efectivo, programas de compra de activos y liquidez extraordinaria); la microestructura y volatilidad de los mercados (saltos extremos, outliers concentrados en mar-abr/2020) y la correlación entre retornos bursátiles y variables reales. Este entorno excepcional vuelve no comparables los parámetros de un modelo estimado junto con el periodo previo. A su vez, el corte enero de 2022 marca la transición a un régimen pospandemia con aceleración inflacionaria y la subsecuente fase de alzas (HIKING) y meseta (PLATEAU) de la tasa de fondos federales, que reconfiguran la transmisión monetaria y las primas de riesgo. Por construcción, estos hitos delimitan tres estados de la economía con reglas y fricciones distintas, lo que fundamenta la segmentación temporal.

En términos econométricos, la partición busca evitar promediar parámetros de regímenes heterogéneos, reduciendo sesgos por inestabilidad estructural (parámetros que cambian entre segmentos), mitigando no linealidades y mejorando la validez de la inferencia. Primero, los outliers pandémicos concentran varianza y rompen supuestos de homocedasticidad/normalidad si se mezclan con épocas regulares; al aislarlos, los diagnósticos (BG, White/BP, RESET, JB) mejoran y los estimadores HAC son más informativos. Segundo, la dependencia del estado capturada también con interacciones  $\Delta EFFR \times \text{régimen}$  (ZLB/HIKING/PLATEAU) se refleja en elasticidades que, de estimarse “todo junto”, se diluyen o cambian de signo por promedios de Simpson. Tercero, la literatura sobre quiebres en tiempo (Chow/efp-CUSUM) anticipa puntos de

cambio alineados con estos hitos; por eso reportamos PRE=25 | COVID=22 | POST=36 y estimamos dentro de cada tramo, dejando trazabilidad para contrastes formales de robustez.

#### 4.6. Especificación y selección ADL por BIC

Con base en los modelos ADL definidos retornos en exceso como dependiente shocks monetarios  $\Delta EFR$  interactuados por régimen y ortogonalizados frente a  $\Delta \log CPI$   $\Delta \log INDPRO$  y  $\Delta UNRATE$  y dummies de marzo y abril de 2020 se realizó una búsqueda por BIC en un grid de rezagos  $\ell$  en 0 1 2 para cada regresor y la inclusión opcional de AR 1 A continuación se reporta por segmento y por índice la combinación seleccionada rezagos elegidos para EFR CPI INDPRO UNRATE y si AR 1 quedó ON u OFF el tamaño muestral efectivo  $n$  el BIC del mejor modelo y el conjunto de regresores retenidos

PRE ene 2018 – feb 2020

S&P 500 BIC selecciona un ADL sin rezagos en explicativas EFR 0 CPI 0 INDPRO 0 UNRATE 0 y sin AR 1  $n = 25$  BIC  $-96.021$  quedaron  $d\_EFR\_BASE$   $\Delta \log CPI$   $\Delta \log INDPRO$  y  $\Delta UNRATE$

NASDAQ 100 especificación análoga rezagos 0 y AR 1 OFF  $n = 25$  BIC  $-85.252$  retenidos  $d\_EFR\_BASE$   $\Delta \log CPI$   $\Delta \log INDPRO$  y  $\Delta UNRATE$

Interpretación antes de la pandemia los retornos en exceso responden contemporáneamente a shocks monetarios fuera de regímenes especiales y a los controles reales sin necesidad de dinámica adicional ni término autorregresivo

COVID mar 2020 – dic 2021

S&P 500 BIC favorece una especificación más dinámica con EFR 2 CPI 2 INDPRO 1

UNRATE 1 y AR 1 ON n 20 BIC  $-106.217$  retenidos d\_EFR\_ZLB  $\Delta \log$  CPI  $\Delta \log$  INDPRO

$\Delta$ UNRATE y  $y_{t-1}$

NASDAQ 100 BIC escoge EFR 0 CPI 1 INDPRO 1 UNRATE 1 y AR 1 OFF n 21 BIC

$-91.091$  retenidos d\_EFR\_ZLB  $\Delta \log$  CPI  $\Delta \log$  INDPRO  $\Delta$ UNRATE y D\_2020m04

Interpretación en el piso de tasas ZLB los shocks monetarios actúan con retrasos y con memoria

para S&P 500 mientras que NASDAQ incorpora la anomalía de abril de 2020 vía dummy y no

requiere AR 1 en ambos casos el canal real permanece activo

POST ene 2022 – dic 2024

S&P 500 y NASDAQ 100 para ambos índices BIC selecciona rezagos 0 en todas las explicativas

y AR 1 OFF n 36 BIC  $-129.785$  S&P 500 y  $-109.986$  NASDAQ retenidos d\_EFR\_HIKING

d\_EFR\_PLATEAU  $\Delta \log$  CPI  $\Delta \log$  INDPRO y  $\Delta$ UNRATE

Interpretación tras el despegue y la meseta de tasas el efecto monetario vuelve a ser

contemporáneo pero dependiente del estado diferenciado entre alzas y meseta y los controles

reales siguen siendo relevantes sin requerir dinámica adicional

## Interpretaciones

### 5.1. Modelo S&P 500 segmento 1

Tabla 5

| Variable    | Estimate   | Std. Error | t value | Pr(> t ) |
|-------------|------------|------------|---------|----------|
| (Intercept) | -0.0062885 | 0.0070812  | -0.8881 | 0.38506  |

|                 |            |           |         |           |
|-----------------|------------|-----------|---------|-----------|
| d_EFFR_BASE_1   | -0.0147256 | 0.0546093 | -0.2697 | 0.79019   |
| dlog_CPIAUCSL_1 | 6.0207166  | 2.3803467 | 2.5293  | 0.01994 * |
| dlog_INDPRO_1   | -1.2339710 | 1.1619152 | -1.0620 | 0.30089   |
| d_UNRATE_1      | -0.0658287 | 0.0644465 | -1.0214 | 0.31924   |

### **d\_EFFR\_BASE\_1 ( $\Delta$ Fed funds fuera de regímenes)**

Por un aumento de 1 punto porcentual en la tasa efectiva de la Fed, el índice S&P 500 disminuye  $\approx 1.47\%$  en su retorno en exceso. La estimación no es significativa ( $p=0.79$ ). La mala significancia puede deberse a la muestra corta ( $n=25$ ), a que los movimientos 2018–2019 fueron ampliamente telegrafados (poco “sorpresa”) y a la alta varianza idiosincrática de los retornos mensuales.

En contexto PRE, 2018 tuvo alzas graduales y 2019 recortes preventivos; el signo negativo es coherente con el mecanismo de descuento (tasas más altas deprimen valuaciones). Que no sea significativo sugiere que el mercado ya había incorporado la información de política con antelación, de modo que la variación contemporánea de EFFR aporta poca señal adicional a los retornos mensuales.

### **dlog\_CPIAUCSL\_1 (inflación mensual)**

Por un aumento de 1% en la inflación mensual, el índice S&P 500 aumenta  $\approx 6.02\%$  en su retorno en exceso. La estimación es significativa al 5% ( $p=0.0199$ ).

En contexto PRE, la inflación aún era moderada y las sorpresas alcistas se asociaban a fuerza de demanda/ventas nominales y poder de fijación de precios, por lo que el canal de

utilidades esperadas dominó, empujando acciones por encima del risk-free pese al efecto de mayor descuento.

### **dlog\_INDPRO\_1 (crecimiento mensual de producción industrial)**

Por un aumento de 1% en la producción industrial mensual, el índice S&P 500 disminuye  $\approx 1.24\%$  en su retorno en exceso. La estimación no es significativa ( $p=0.301$ ). La baja significancia puede surgir porque INDPRO es un indicador rezagado (poca sorpresa para el mercado), la muestra es pequeña y existe solapamiento cíclico con CPI.

En el PRE, hacia fines de 2019 la actividad industrial se enfrió; el equity suele anticipar estos giros con otros líderes, por lo que la señal contemporánea de INDPRO difícilmente explique variaciones mensuales una vez controlamos por otras noticias.

### **d\_UNRATE\_1 ( $\Delta$ tasa de desempleo)**

Por un aumento de 1 punto porcentual en la tasa de desempleo, el índice S&P 500 disminuye  $\approx 6.58\%$  en su retorno en exceso. La estimación no es significativa ( $p=0.319$ ). La mala significancia refleja que cambios mensuales tan grandes en desempleo son raros en PRE y que el mercado suele descontar empleo con indicadores líderes (claims, encuestas) antes del dato oficial.

En el PRE, el desempleo permaneció bajo y estable; cuando subía, coincidía con episodios de aversión al riesgo, pero el tamaño muestral y la anticipación de noticias impiden estimar el efecto con precisión.

### **Intercepto**

Por término medio, controlando por las covariables, el índice S&P 500 presenta un – 0.63% de retorno en exceso, no significativo ( $p=0.385$ ), consistente con una prima media residual no distinguible de cero en esta submuestra corta.

### **Ajuste global**

El modelo explica  $\approx 9.7\%$  de la variación mensual ( $R^2$  ajustado = 0.097) y no es significativo en conjunto ( $F(4,20)=1.65$ ,  $p=0.202$ ). En síntesis, dentro del PRE la única señal con poder estadístico es la inflación mensual, mientras que política monetaria contemporánea, actividad real y desempleo no muestran efectos distinguibles dado el horizonte mensual y el tamaño de la muestra.

## **5.2. Modelo NASDAQ 100 segmento 1**

Tabla 6

| <b>Variable</b> | <b>Estimate</b> | <b>Std. Error</b> | <b>t value</b> | <b>Pr(&gt; t )</b> |
|-----------------|-----------------|-------------------|----------------|--------------------|
| (Intercept)     | -0.0039663      | 0.0119009         | -0.3333        | 0.74239            |
| d_EFFR_BASE_1   | -0.013896       | 0.0674487         | -0.2060        | 0.83885            |
| dlog_CPIAUCSL_1 | 8.4151465       | 4.3216700         | 1.9472         | 0.06569 .          |
| dlog_INDPRO_1   | -1.7304773      | 1.4016836         | -1.2346        | 0.23130            |

|            |            |           |         |         |
|------------|------------|-----------|---------|---------|
| d_UNRATE_1 | -0.0619846 | 0.0732404 | -0.8463 | 0.40739 |
|------------|------------|-----------|---------|---------|

### **d\_EFFR\_BASE\_1 ( $\Delta$ Fed funds fuera de regímenes)**

Por un aumento de 1 punto porcentual en la tasa efectiva de la Fed, el índice NASDAQ-100 disminuye  $\approx 1.39\%$  en su retorno en exceso. La estimación no es significativa ( $p=0.839$ ). La mala significancia puede deberse a la muestra corta ( $n=25$ ), a que los movimientos 2018–2019 fueron ampliamente anticipados por el mercado y a la alta varianza idiosincrática de los retornos tecnológicos.

### **dlog\_CPIAUCSL\_1 (inflación mensual)**

Por un aumento de 1% en la inflación mensual, el índice NASDAQ-100 aumenta  $\approx 8.42\%$  en su retorno en exceso. La estimación es marginalmente significativa al 10% ( $p=0.0657$ ). La cercanía al umbral sugiere señal económica con poder estadístico limitado por tamaño muestral y posible colinealidad con actividad real.

### **dlog\_INDPRO\_1 (crecimiento mensual de producción industrial)**

Por un aumento de 1% en la producción industrial mensual, el índice NASDAQ-100 disminuye  $\approx 1.73\%$  en su retorno en exceso. La estimación no es significativa ( $p=0.231$ ). Puede deberse a que INDPRO es indicador rezagado y aporta poca sorpresa una vez incorporadas otras noticias, además de la menor relación directa entre manufactura y grandes tecnológicas.

### **d\_UNRATE\_1 ( $\Delta$ tasa de desempleo)**

Por un aumento de 1 punto porcentual en la tasa de desempleo, el índice NASDAQ-100 disminuye  $\approx 6.20\%$  en su retorno en exceso. La estimación no es significativa ( $p=0.407$ ). La baja potencia estadística viene de que cambios mensuales tan grandes en desempleo fueron raros en PRE y el mercado suele anticiparlos con indicadores líderes.

### **Intercepto**

En promedio, controlando por covariables, el índice NASDAQ-100 presenta un  $-0.40\%$  de retorno en exceso mensual, no significativo ( $p=0.742$ ).

### **Ajuste global**

El modelo explica  $\approx 11.0\%$  de la variación mensual ( $R^2$  ajustado = 0.110) y no es significativo en conjunto ( $F(4,20)=1.74$ ,  $p=0.1811$ ).

### **Interpretación económica y contexto PRE**

En el periodo PRE (2018-02/2020-02) el NASDAQ-100 mostró alta sensibilidad a noticias de demanda nominal: las sorpresas de inflación (posiblemente percibidas como reflejo de ventas fuertes y poder de precio en grandes plataformas tecnológicas) se asociaron con retornos en exceso positivos, pese al canal de descuento adverso, lo que sugiere que el efecto utilidades dominó al de tasas en el corto plazo. Los cambios contemporáneos de la Fed no exhiben efecto detectable, consistente con una política muy telegrafiada y con que los shocks relevantes para equity fueron las expectativas más que el movimiento mecánico de la tasa efectiva. La actividad real (INDPRO) y el desempleo añadieron poca información contemporánea para explicar retornos mensuales del NASDAQ, dado su carácter menos sincronizado con el ciclo industrial y la anticipación del mercado. En suma, en esta submuestra corta la única palanca con algo de señal estadística es la inflación mensual, coherente con un régimen donde el crecimiento de ingresos nominales de las grandes tecnológicas pesó más que la duración.

## **5.3. Modelo S&P 500 segmento 2**

Tabla 7

| Variable        | Estimate   | Std. Error | t value  | Pr(> t )          |
|-----------------|------------|------------|----------|-------------------|
| (Intercept)     | 0.0506593  | 0.0023080  | 21.9495  | 0.000000000003037 |
| d_EFFR_ZLB_1    | -0.0490555 | 0.0106430  | -4.6092  | 0.0004053         |
| dlog_CPIAUCSL_1 | -4.4678035 | 0.2014547  | -22.1777 | 0.000000000002638 |
| dlog_INDPRO_1   | 0.9137229  | 0.1068625  | 8.5505   | 0.000000625912273 |
| d_UNRATE_1      | 0.0167782  | 0.0020879  | 8.0360   | 0.000001299642042 |
| y_L1            | -0.2654554 | 0.0399404  | -6.6463  | 0.000011027942867 |

#### **d\_EFFR\_ZLB\_1 ( $\Delta$ Fed funds dentro del ZLB)**

Por un aumento de 1 punto porcentual en la tasa efectiva de la Fed durante el ZLB el índice S&P 500 disminuye  $\approx 4.91\%$  en su retorno en exceso. Es altamente significativo ( $p=0.00041$ ) lo que indica un efecto estadístico y económico fuerte en este subrégimen.

#### **dlog\_CPIAUCSL\_1 (inflación mensual)**

Por un aumento de 1% en la inflación mensual el índice S&P 500 disminuye  $\approx 4.47\%$  en su retorno en exceso. Es altamente significativo ( $p\approx 2.6e-12$ ) y con magnitud grande sugiriendo que sorpresas de precios fueron netamente contractivas para equity en COVID.

#### **dlog\_INDPRO\_1 (crecimiento mensual de producción industrial)**

Por un aumento de 1% en la producción industrial mensual el índice S&P 500 aumenta  $\approx 0.91\%$  en su retorno en exceso. Es altamente significativo ( $p\approx 6.26e-7$ ) coherente con que mejores datos reales impulsaron utilidades esperadas y apetito por riesgo.

### **d\_UNRATE\_1 ( $\Delta$ tasa de desempleo)**

Por un aumento de 1 punto porcentual en la tasa de desempleo el índice S&P 500 aumenta  $\approx 1.68\%$  en su retorno en exceso. Es altamente significativo ( $p \approx 1.30e-6$ ). El signo positivo, contraintuitivo en tiempos normales, es consistente con el episodio COVID donde peores datos laborales activaban expectativas de mayor estímulo fiscal/monetario, elevando precios de activos.

### **y\_L1 (retorno en exceso rezagado AR(1))**

Por un aumento de 1% en el retorno en exceso del mes anterior el índice S&P 500 disminuye  $\approx 0.27\%$  este mes. Es altamente significativo ( $p \approx 1.10e-5$ ) y refleja mean reversion fuerte en la volatilidad extrema del periodo.

### **Intercepto**

En promedio, con las covariables en cero, el índice S&P 500 presenta un  $\approx +5.07\%$  de retorno en exceso mensual en la muestra COVID. Altamente significativo; léase como media condicional del régimen, no como efecto causal.

### **Ajuste global**

El modelo explica  $\approx 68.2\%$  de la variación mensual ( $R^2$  ajustado = 0.682) y es significativo en conjunto ( $F(5,14)=9.14$ ,  $p=0.0005$ ).

### **Interpretación económica y contexto COVID**

Durante COVID (2020-03 a 2021-12), en régimen ZLB, el precio del equity respondió de manera muy sensible a shocks macro y de política. Las sorpresas de inflación tuvieron un efecto fuertemente negativo sobre los retornos en exceso, indicando que el canal de descuento (tasas reales esperadas más altas y mayor prima por riesgo) dominó con claridad al canal de utilidades. Los mejores datos reales (INDPRO) impulsaron al S&P 500, mientras que los deterioros

laborales (UNRATE) coincidieron con subidas en equity porque el mercado internalizaba respuestas de política expansivas extraordinarias (QE, fiscal masivo), un patrón típico de “bad news is good news” en crisis con respaldo de autoridades. Dentro del ZLB, movimientos al alza de la Fed funds (aunque raros y de pequeña magnitud operativa) se asociaron con caídas significativas en retornos, consistente con un entorno extremadamente dependiente de liquidez. La fuerte reversión ( $y_{L1} < 0$ ) captura la dinámica de sobre-reacción y correcciones mensuales en un periodo de volatilidad histórica. En suma, la combinación de alta potencia estadística y signos coherentes con la narrativa de estímulos y sorpresas inflacionarias hace que este sea un modelo robusto para el tramo COVID.

#### 5.4. Modelo NASDAQ 100 segmento 2

Tabla 8

| Variable        | Estimate   | Std. Error | t value | Pr(> t )              |
|-----------------|------------|------------|---------|-----------------------|
| (Intercept)     | -0.0665523 | 0.0051937  | -12.814 | 0.0000000017539733697 |
| d_EFFR_ZLB_1    | 1.6692306  | 0.0851408  | 19.605  | 0.0000000000042101503 |
| dlog_CPIAUCSL_1 | 14.7838972 | 0.7479783  | 19.765  | 0.0000000000037439349 |

|               |           |           |        |                        |
|---------------|-----------|-----------|--------|------------------------|
| dlog_INDPRO_1 | 3.6713814 | 0.0985495 | 37.254 | 0.0000000000000003363  |
| d_UNRATE_1    | 0.0302929 | 0.0021853 | 13.862 | 0.0000000005881541739  |
| D_2020m04     | 0.9976660 | 0.0449359 | 22.202 | 0.00000000000006911351 |

### **d\_EFFR\_ZLB\_1 ( $\Delta$ Fed funds dentro del ZLB)**

Por un aumento de 1 punto porcentual en la tasa efectiva de la Fed durante el ZLB el índice NASDAQ 100 aumenta  $\approx 166.9\%$  en su retorno en exceso. Es altamente significativo ( $p \approx 4.2e-12$ ). La magnitud es muy grande para datos mensuales y sugiere que en este subrégimen los cambios de EFFR co-movieron fuertemente con shocks de liquidez/confianza.

### **dlog\_CPIAUCSL\_1 (inflación mensual)**

Por un aumento de 1% en la inflación mensual el índice NASDAQ 100 aumenta  $\approx 14.78\%$  en su retorno en exceso. Es altamente significativo ( $p \approx 3.7e-12$ ).

### **dlog\_INDPRO\_1 (crecimiento mensual de producción industrial)**

Por un aumento de 1% en la producción industrial mensual el índice NASDAQ 100 aumenta  $\approx 3.67\%$  en su retorno en exceso. Es altamente significativo ( $p \approx 3.36e-16$ ).

### **d\_UNRATE\_1 ( $\Delta$ tasa de desempleo)**

Por un aumento de 1 punto porcentual en la tasa de desempleo el índice NASDAQ 100 aumenta  $\approx 3.03\%$  en su retorno en exceso. Es altamente significativo ( $p \approx 5.88e-10$ ).

### **D\_2020m04 (dummy abril 2020)**

En abril de 2020 el índice NASDAQ 100 aumenta  $\approx 99.8\%$  adicional en su retorno en exceso respecto a un mes típico con iguales covariables. Es altamente significativo ( $p \approx 6.91e-13$ ). El tamaño sugiere que esta dummy concentra gran parte del rebote extremo de inicios de QE y

anuncios fiscales.

### **Intercepto**

Con las covariables en cero el retorno en exceso medio condicional del NASDAQ 100 es  $\approx -6.66\%$  mensual. Es altamente significativo ( $p \approx 1.75e-9$ ) y refleja el sesgo bajista promedio que el modelo compensa con los shocks explicativos.

### **Ajuste global**

El modelo explica  $\approx 72.3\%$  de la variación mensual ( $R^2$  ajustado = 0.723) y es significativo en conjunto ( $F(5,15)=11.44$ ,  $p=0.0001$ ).

### **Interpretación económica y contexto COVID**

Durante COVID (2020-03 a 2021-12), el NASDAQ —intensivo en tecnología y duración— reaccionó muy positivamente a señales de liquidez y a expectativas de política expansiva. El signo positivo de inflación y desempleo es coherente con un régimen “bad news is good news”: peores datos reales o sorpresas de precios reforzaban la probabilidad de más estímulo monetario y fiscal, comprimiendo tasas reales y elevando valuaciones de crecimiento. El crecimiento de INDPRO también suma porque mejora utilidades esperadas. A diferencia del S&P 500 en COVID, aquí el coeficiente de  $\Delta EFR$  dentro del ZLB aparece positivo y enorme: en el subrango cercano a cero, micro-variaciones de la EFR se alinearon con fases de normalización/reapertura y con operaciones técnicas de liquidez, correlacionándose con rallies de tech. La dummy de abril-2020 capta el rebote excepcional posterior al crash de marzo y a los anuncios coordinados de QE ilimitado y paquetes fiscales. En conjunto el patrón describe un mercado hipersensible a estímulos y a noticias de crecimiento, con respuestas especialmente potentes en sectores de alto duration como el NASDAQ.

### 5.5. Modelo S&P 500 segmento 3

Tabla 9

| Variable         | Estimate  | Std. Error | t value | Pr(> t )       |
|------------------|-----------|------------|---------|----------------|
| (Intercept)      | 0.0242840 | 0.0051937  | 4.1995  | 0.0002201 ***  |
| d_EFFR_HIKING_1  | 0.0037406 | 0.0851408  | 0.1618  | 0.8725366      |
| d_EFFR_PLATEAU_1 | -0.086301 | 0.7479783  | -2.015  | 0.0529307 .    |
| dlog_CPIAUCSL_1  | -6.286985 | 0.0985495  | -4.898  | 0.00003104 *** |
| dlog_INDPRO_1    | 0.7215623 | 0.0021853  | 1.2190  | 0.2323375      |
| d_UNRATE_1       | 0.0325320 | 0.0449359  | 0.6517  | 0.5195346      |

#### **d\_EFFR\_HIKING\_1 ( $\Delta$ Fed funds en fase de alzas)**

Por un aumento de 1 punto porcentual en la tasa efectiva de la Fed durante la fase de alzas el índice S&P 500 aumenta  $\approx 0.37\%$  en su retorno en exceso. No es significativo ( $p \approx 0.873$ ). La mala significancia puede deberse a que los movimientos relevantes fueron de pocos bp (25–75 bp), a fuerte heterogeneidad sectorial en 2022–2023 y a que el mercado anticipó gran parte del ciclo con la guía futura de la Fed.

#### **d\_EFFR\_PLATEAU\_1 ( $\Delta$ Fed funds en fase de meseta)**

Por un aumento de 1 punto porcentual en la tasa efectiva de la Fed durante la meseta el S&P 500 disminuye  $\approx 8.63\%$  en su retorno en exceso. Es marginalmente significativo ( $p \approx 0.053$ ). A escala realista: +25 bp  $\approx -2.16\%$ . Sugiere compresión de múltiplos cuando el mercado percibe prolongación/repuntes de tasas en la meseta.

### ***dlog\_CPIAUCSL\_1 (inflación mensual)***

Por un aumento de 1% en la inflación mensual el S&P 500 disminuye  $\approx 6.29\%$  en su retorno en exceso. Es altamente significativo ( $p \approx 3.1e-5$ ). Señala que en el post-COVID las sorpresas de inflación volvieron a ser claramente “riesgo-off”.

### **dlog\_INDPRO\_1**

Por un aumento de 1% en la producción industrial mensual el S&P 500 aumenta  $\approx 0.72\%$  en su retorno en exceso. No es significativo ( $p \approx 0.232$ ). La baja potencia puede reflejar rezagos más largos desde actividad real a precios de acciones y la concentración de retornos en mega-cap tech (poca correlación con INDPRO).

### **d\_UNRATE\_1 ( $\Delta$ tasa de desempleo)**

Por un aumento de 1 punto porcentual en la tasa de desempleo el S&P 500 aumenta  $\approx 3.25\%$  en su retorno en exceso. No es significativo ( $p \approx 0.520$ ). Puede reflejar señales mixtas de “bad-news-is-good-news” cuando mayores desempleos elevan la probabilidad de recortes, pero sin potencia estadística en esta especificación.

### **Intercepto**

Con las covariables en cero el retorno en exceso medio condicional del S&P 500 es  $\approx +2.43\%$  mensual, significativo ( $p \approx 0.00022$ ). Capta un sesgo alcista medio del periodo condicionado por el boom de 2023–2024.

### **Ajuste global**

El modelo explica  $\approx 16.8\%$  de la variación ( $R^2$  ajustado = 0.168) y es marginal en conjunto ( $F(5,30)=2.41$ ,  $p=0.0592$ ). Poder explicativo moderado—coherente con un régimen dominado por shocks idiosincráticos (IA mega-caps, recompras, geopolítica) además de macro.

### **Interpretación económica y contexto POST**

En POST (2022-01 a 2024-12) el mercado transitó de subidas agresivas de tasas (alzas) a una meseta prolongada con QT. A diferencia del COVID, las sorpresas de inflación penalizan fuertemente a las acciones (coeficiente negativo y significativo), reflejando temor a tasas reales altas y a persistencia inflacionaria. En la meseta, incrementos adicionales de la EFR (o su expectativa) se asocian con caídas del S&P 500 ( $-8.6\%$  por  $+1$  pp; efecto relevante ya desde  $+25$  bp  $\approx -2.16\%$ ), consistente con compresión de valuaciones cuando el “higher for longer” se prolonga. En cambio, durante la fase de alzas el coeficiente no es estadísticamente distinto de cero, probablemente porque gran parte del ajuste de precios ocurrió antes o porque los shocks estaban descontados vía forward guidance. Los datos reales (INDPRO, UNRATE) no muestran impacto contemporáneo robusto, en línea con un ciclo en el que la narrativa de inflación y tasas dominó, mientras los retornos se concentraron en mega-cap de IA, reduciendo la sensibilidad del índice agregado a indicadores macro tradicionales.

## 5.6. Modelo NASDAQ 100segmento 3

Tabla 10

| Variable       | Estimate  | Std. Error | t value | Pr(> t )         |
|----------------|-----------|------------|---------|------------------|
| (Intercept)    | 0.0369386 | 0.0078885  | 4.6826  | 0.0000570101 *** |
| d_EFR_HIKING_1 | -0.003670 | 0.0182340  | -0.201  | 0.84185          |
| d_EFR_PLATEAUI | -0.104050 | 0.0483968  | -2.150  | 0.03974 *        |

|                 |           |           |        |                  |
|-----------------|-----------|-----------|--------|------------------|
| dlog_CPIAUCSL_1 | -9.837838 | 1.4423030 | -6.820 | 0.0000001443 *** |
| dlog_INDPRO_1   | 1.0544719 | 0.7185648 | 1.4675 | 0.15265          |
| d_UNRATE_1      | 0.0498422 | 0.0623823 | 0.7990 | 0.43058          |

### **d\_EFFR\_HIKING\_1 ( $\Delta$ Fed funds en fase de alzas)**

Por un aumento de 1 punto porcentual en la tasa efectiva de la Fed durante la fase de alzas, el NASDAQ 100 disminuye  $\approx 0.37\%$  en su retorno en exceso. No es significativo ( $p \approx 0.842$ ). La baja potencia puede deberse a que los movimientos efectivos fueron de 25–75 bp, a que el mercado los descontó por guía futura, y a que el rally 2023–2024 estuvo dominado por factores idiosincráticos (IA mega-caps) más que por el nivel puntual de la EFFR.

### **d\_EFFR\_PLATEAU\_1 ( $\Delta$ Fed funds en fase de meseta)**

Por un aumento de 1 punto porcentual en la EFFR durante la meseta, el NASDAQ 100 disminuye  $\approx 10.41\%$  en su retorno en exceso (significativo,  $p \approx 0.0397$ ). A escala realista: +25 bp  $\approx -2.60\%$ . Consistente con compresión de múltiplos cuando el mercado internaliza un “higher for longer”.

### **dlog\_CPIAUCSL\_1 (inflación mensual)**

Por un aumento de 1% en la inflación mensual, el NASDAQ 100 disminuye  $\approx 9.84\%$  en su retorno en exceso. Altamente significativo ( $p \approx 1.44e-7$ ). La bolsa tech es especialmente sensible a sorpresas inflacionarias vía tasas reales y valuaciones de larga duración.

### **dlog\_INDPRO\_1 (crecimiento mensual de producción industrial)**

Por un aumento de 1% en la producción industrial, el NASDAQ 100 aumenta  $\approx 1.05\%$ . No es significativo ( $p \approx 0.153$ ). La actividad real contemporánea explica poco el índice al estar

concentrado en empresas de crecimiento global con baja ciclicidad industrial.

### **d\_UNRATE\_1 ( $\Delta$ tasa de desempleo)**

Por un aumento de 1 punto porcentual en el desempleo, el NASDAQ 100 aumenta  $\approx 4.98\%$ . No es significativo ( $p \approx 0.431$ ). El signo sugiere un canal de “bad-news-is-good-news” (mayor probabilidad de recortes), pero sin evidencia estadística robusta.

### **Intercepto**

Con las covariables en cero, el retorno en exceso medio condicional del NASDAQ 100 es  $\approx +3.69\%$  mensual, significativo ( $p \approx 5.7e-5$ ). Refleja el sesgo alcista medio del periodo por el rally de IA.

### **Ajuste global**

El modelo explica  $\approx 24.8\%$  de la variación ( $R^2$  ajustado = 0.248) y es significativo en conjunto ( $F(5,30)=3.31$ ,  $p=0.0168$ ).

### **Interpretación económica y contexto POST**

En POST (2022–2024), con inflación todavía elevada, QT y una meseta de tasas altas, el NASDAQ 100 mostró fuerte aversión a sorpresas de inflación (coeficiente negativo y grande) y castigó incrementos de la EFR dentro de la meseta ( $-10.4\%$  por +1 pp;  $\approx -2.6\%$  por +25 bp), coherente con valuaciones de alta duración muy sensibles a la tasa de descuento. En contraste, los movimientos durante la fase de alzas no muestran efecto estadísticamente distinto de cero—probablemente porque el ajuste ya estaba descontado y porque el impulso de beneficios/expectativas de IA dominó el precio de mercado. La actividad real (INDPRO) y el desempleo (UNRATE) no presentan impactos contemporáneos robustos, reforzando que, en este tramo, inflación y expectativas de tasas fueron los principales drivers macro, mientras el componente idiosincrático de mega-cap tech explicó buena parte del rendimiento relativo del

NASDAQ.

## Conclusiones

Entre 2018 y 2024, la relación entre la tasa efectiva de los fondos federales (EFFR) y los principales índices bursátiles de Estados Unidos evolucionó bajo condiciones económicas muy distintas. Antes de la pandemia, con tasas bajas y expectativas estables, los movimientos de la EFFR apenas se reflejaron en los rendimientos del S&P 500 y el NASDAQ-100. En esa etapa, el mercado reaccionó principalmente a noticias nominales, mientras los cambios de política monetaria eran pequeños, esperados y absorbidos sin sobresaltos.

Durante la pandemia, la dinámica cambió de manera drástica. Con tasas cercanas a cero, liquidez abundante y elevada incertidumbre, la respuesta del mercado divergió entre los índices. En el S&P 500, incluso leves señales de endurecimiento redujeron las valoraciones al aumentar la tasa de descuento en un entorno frágil. En el NASDAQ-100, en cambio, la liquidez masiva y la aceleración de la digitalización sostuvieron los precios pese a señales menos expansivas. Esto reflejó cómo el sector tecnológico se benefició de los estímulos fiscales y de las expectativas de productividad.

A partir de 2022, con la normalización y la meseta monetaria, el canal del descuento volvió a dominar. La EFFR ejerció un efecto contractivo más claro, especialmente sobre el NASDAQ-100, dado que las empresas de crecimiento son más sensibles al aumento del costo del

capital. Aunque la producción industrial y el empleo ofrecieron alivios temporales, las valoraciones pasaron a estar determinadas por la persistencia de las tasas altas y el nuevo equilibrio de riesgo.

Las variables de control también modificaron su influencia a lo largo del periodo. La inflación impulsó los rendimientos nominales antes de 2020, se convirtió en freno durante la recuperación y volvió a ser un factor clave en la etapa de desinflación. La producción industrial y el desempleo reflejaron el rebote del ciclo, pero perdieron protagonismo cuando el foco de los inversionistas se centró en cuánto tiempo se mantendría la restricción monetaria. Esto confirma que un único modelo para todo el periodo habría ocultado mecanismos distintos y señales relevantes.

El diseño econométrico segmentado fue esencial para aislar estos efectos. Transformar las series para garantizar estacionariedad, dividir la muestra según cambios de régimen y aplicar correcciones robustas (Newey–West) permitió resultados estables y comprensibles. La inclusión de variables dummy para los meses críticos de 2020 y el tratamiento cuidadoso de los valores atípicos ayudaron a distinguir entre patrones estructurales y choques transitorios.

Desde una perspectiva aplicada, los resultados muestran que el efecto de la política monetaria depende del contexto. En escenarios de alta liquidez y narrativas de productividad, los mercados pueden sostenerse pese a señales contractivas. En cambio, en fases de desinflación prolongada con tasas altas, el factor de descuento domina las valoraciones. Para la comunicación de política, importa tanto el nivel de la tasa como la señal transmitida sobre su trayectoria. Para los inversionistas, interpretar las decisiones de la Fed requiere leer la señal de tasas según el régimen vigente y la composición sectorial del portafolio.

El estudio reconoce limitaciones razonables: la EFR no captura las herramientas no convencionales ni toda la orientación prospectiva de la Fed; la frecuencia mensual no refleja reacciones intrames; y el periodo incluye choques simultáneos difíciles de separar completamente. Futuras investigaciones podrían incorporar sorpresas de alta frecuencia, análisis sectoriales y nuevos ciclos de recorte para validar la robustez.

En conclusión, los resultados confirman que la política monetaria de la Reserva Federal influye de manera significativa en los mercados bursátiles, aunque su intensidad y dirección varían según la fase y la naturaleza del índice. La estabilidad previa al COVID atenuó el efecto de la tasa, la liquidez pandémica lo revirtió y la normalización lo reimpuso. Comprender estas sensibilidades dependientes del régimen ayuda a los inversionistas a anticipar cuándo las señales monetarias realmente importan para la toma de decisiones, y refuerza el valor de usar modelos segmentados y robustos como herramientas de análisis y gestión.

## Anexos

**Salidas ADF en nivel (lag óptimo por BIC)**

```
==== ADF(auto) :: SP500 (nivel) ====
Determinístico: trend | Criterio: BIC | Lag óptimo: 9

#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####

Test regression trend

Call:
lm(formula = z.diff ~ z.lag.1 + 1 + tt + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-641.37 -65.70  33.45  88.33 211.69

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept) 166.41180   116.79278   1.425  0.1586
z.lag.1      -0.07292    0.04851  -1.503  0.1373
tt           3.42834    1.90682   1.798  0.0765
z.diff.lag   0.14782    0.12024   1.229  0.2230
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 142.8 on 70 degrees of freedom
Multiple R-squared:  0.05987, Adjusted R-squared:  0.01958
F-statistic: 1.486 on 3 and 70 DF, p-value: 0.2259
```

value of test-statistic is: -1.5031 2.7811 1.6694

Critical values for test statistics:

|      | 1pct  | 5pct  | 10pct |
|------|-------|-------|-------|
| tau3 | -4.04 | -3.45 | -3.15 |
| phi2 | 6.50  | 4.88  | 4.16  |
| phi3 | 8.73  | 6.49  | 5.47  |

[adf.test] (contraste con mismo k)

Augmented Dickey-Fuller Test

data: x  
Dickey-Fuller = -2.5976, Lag order = 9, p-value = 0.3307  
alternative hypothesis: stationary

```
==== ADF(auto) :: CPIAUCSL (nivel) ====
Determinístico: trend | Criterio: BIC | Lag óptimo: 9
```

```
#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####
```

Test regression trend

```
Call:
lm(formula = z.diff ~ z.lag.1 + 1 + tt + z.diff.lag)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-2.30431 -0.35329 -0.00722  0.28020  2.04777
```

```
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  8.87895    4.11060   2.160  0.0342 *
z.lag.1      -0.03708    0.01762  -2.104  0.0389 *
tt           0.04237    0.01876   2.259  0.0270 *
z.diff.lag   0.51572    0.09862   5.230 0.00000168 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 0.7248 on 70 degrees of freedom  
Multiple R-squared: 0.3481, Adjusted R-squared: 0.3202  
F-statistic: 12.46 on 3 and 70 DF, p-value: 0.000001278

value of test-statistic is: -2.1043 5.5823 2.6635

Critical values for test statistics:

|      | 1pct  | 5pct  | 10pct |
|------|-------|-------|-------|
| tau3 | -4.04 | -3.45 | -3.15 |
| phi2 | 6.50  | 4.88  | 4.16  |
| phi3 | 8.73  | 6.49  | 5.47  |

[adf.test] (contraste con mismo k)

Augmented Dickey-Fuller Test

data: x  
Dickey-Fuller = -2.7738, Lag order = 9, p-value = 0.2585  
alternative hypothesis: stationary

```
==== ADF(auto) :: NASDAQ100 (nivel) ====
Determinístico: trend | Criterio: BIC | Lag óptimo: 9
```

```
#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####
```

Test regression trend

```
Call:
lm(formula = z.diff ~ z.lag.1 + 1 + tt + z.diff.lag)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-1697.67 -299.47  89.71  383.17 1117.38
```

```
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept) 328.12147   267.84730   1.225  0.2247
z.lag.1      -0.05587    0.04043  -1.382  0.1714
tt          11.54323    7.10789   1.624  0.1089
z.diff.lag   0.21508    0.11849   1.815  0.0738
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 579.9 on 70 degrees of freedom  
Multiple R-squared: 0.07288, Adjusted R-squared: 0.03314  
F-statistic: 1.834 on 3 and 70 DF, p-value: 0.1489

value of test-statistic is: -1.3819 2.5825 1.3311

Critical values for test statistics:

|      | 1pct  | 5pct  | 10pct |
|------|-------|-------|-------|
| tau3 | -4.04 | -3.45 | -3.15 |
| phi2 | 6.50  | 4.88  | 4.16  |
| phi3 | 8.73  | 6.49  | 5.47  |

[adf.test] (contraste con mismo k)

Augmented Dickey-Fuller Test

data: x  
Dickey-Fuller = -2.4038, Lag order = 9, p-value = 0.4103  
alternative hypothesis: stationary

```
==== ADF(auto) :: INDPRO (nivel) ====
Determinístico: drift | Criterio: BIC | Lag óptimo: 9
```

```
#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####
```

Test regression drift

```
Call:
lm(formula = z.diff ~ z.lag.1 + 1 + z.diff.lag)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-12.3960 -0.2315  0.1702  0.6151  2.6187
```

```
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept) 18.46709    6.11839   3.018  0.00353 **
z.lag.1      -0.18300    0.06058  -3.021  0.00350 **
z.diff.lag   0.27881    0.11376   2.451  0.01672 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 1.803 on 71 degrees of freedom  
Multiple R-squared: 0.1459, Adjusted R-squared: 0.1218  
F-statistic: 6.063 on 2 and 71 DF, p-value: 0.003707

value of test-statistic is: -3.0211 4.564

Critical values for test statistics:

|      | 1pct  | 5pct  | 10pct |
|------|-------|-------|-------|
| tau2 | -3.51 | -2.89 | -2.58 |
| phi1 | 6.70  | 4.71  | 3.86  |

[adf.test] (contraste con mismo k)

Augmented Dickey-Fuller Test

data: x  
Dickey-Fuller = -1.9721, Lag order = 9, p-value = 0.5873  
alternative hypothesis: stationary

```

==== ADF(auto) :: UNRATE (nivel) ====
Determinístico: drift | Criterio: BIC | Lag óptimo: 9

#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####

Test regression drift

Call:
lm(formula = z.diff ~ z.lag.1 + 1 + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-0.7517 -0.2954 -0.1904 -0.0583  0.2345

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)   0.94105    0.36194   2.600  0.01133 *
z.lag.1       -0.19901    0.07042  -2.826  0.00612 **
z.diff.lag    0.11115    0.11783   0.943  0.34871
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 1.248 on 71 degrees of freedom
Multiple R-squared:  0.1012,    Adjusted R-squared:  0.07592
F-statistic: 3.999 on 2 and 71 DF,  p-value: 0.02262

Value of test-statistic is: -2.8259 3.9932

Critical values for test statistics:
      1pct  5pct 10pct
tau2 -3.51 -2.89 -2.58
phi1  6.70  4.71  3.86

[adf.test] (contraste con mismo k)

      Augmented Dickey-Fuller Test

data: x
Dickey-Fuller = -2.1232, Lag order = 9, p-value = 0.5254
alternative hypothesis: stationary

```

## Salidas ADF en transformaciones

```

==== ADF(auto) :: dlog_SP500 (retorno) ====
Determinístico: none | Criterio: BIC | Lag óptimo: 9

#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####

Test regression none

Call:
lm(formula = z.diff ~ z.lag.1 - 1 + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-0.210089 -0.007165  0.019143  0.034780  0.067875

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
z.lag.1       -0.91620    0.15612  -5.869 0.000000129 ***
z.diff.lag    0.04572    0.11795   0.388   0.699
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.04205 on 71 degrees of freedom
Multiple R-squared:  0.44,    Adjusted R-squared:  0.4242
F-statistic: 27.89 on 2 and 71 DF,  p-value: 0.00000000115

Value of test-statistic is: -5.8685

Critical values for test statistics:
      1pct  5pct 10pct
tau1 -2.6 -1.95 -1.61

[adf.test] (contraste con mismo k)

      Augmented Dickey-Fuller Test

data: x
Dickey-Fuller = -2.156, Lag order = 9, p-value = 0.5119
alternative hypothesis: stationary

```

```

==== ADF(auto) :: EFR (nivel) ====
Determinístico: drift | Criterio: BIC | Lag óptimo: 9

#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####

Test regression drift

Call:
lm(formula = z.diff ~ z.lag.1 + 1 + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-0.98337 -0.03388  0.00228  0.03368  0.36781

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)   0.026591    0.030147   0.882   0.381
z.lag.1       -0.008606    0.009628  -0.894   0.374
z.diff.lag    0.679257    0.088397   7.684 0.000000000644 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.1709 on 71 degrees of freedom
Multiple R-squared:  0.4541,    Adjusted R-squared:  0.4387
F-statistic: 29.53 on 2 and 71 DF,  p-value: 0.00000000466

Value of test-statistic is: -0.8938 0.4521

Critical values for test statistics:
      1pct  5pct 10pct
tau2 -3.51 -2.89 -2.58
phi1  6.70  4.71  3.86

[adf.test] (contraste con mismo k)

      Augmented Dickey-Fuller Test

data: x
Dickey-Fuller = -2.4897, Lag order = 9, p-value = 0.375
alternative hypothesis: stationary

```

```

==== ADF(auto) :: dlog_NASDAQ (retorno) ====
Determinístico: none | Criterio: BIC | Lag óptimo: 9

#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####

Test regression none

Call:
lm(formula = z.diff ~ z.lag.1 - 1 + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-0.17722 -0.01256  0.02041  0.04780  0.10947

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
z.lag.1       -0.790560    0.148400  -5.327 0.00000112 ***
z.diff.lag    -0.001637    0.118079  -0.014   0.989
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.05031 on 71 degrees of freedom
Multiple R-squared:  0.3969,    Adjusted R-squared:  0.3799
F-statistic: 23.36 on 2 and 71 DF,  p-value: 0.00000001601

Value of test-statistic is: -5.3272

Critical values for test statistics:
      1pct  5pct 10pct
tau1 -2.6 -1.95 -1.61

[adf.test] (contraste con mismo k)

      Augmented Dickey-Fuller Test

data: x
Dickey-Fuller = -2.1397, Lag order = 9, p-value = 0.5186
alternative hypothesis: stationary

```

```

==== ADF(auto) :: dlog_CPIAUCSL (inflación) ====
Determinístico: drift | Criterio: BIC | Lag óptimo: 9

#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####

Test regression drift

Call:
lm(formula = z.diff ~ z.lag.1 + 1 + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-0.0084005 -0.0014774  0.0002232  0.0014520  0.0065883

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  0.0011971  0.0004781   2.504  0.01465 *
z.lag.1      -0.3694171  0.1211965  -3.048  0.00326 **
z.diff.lag1  0.0049133  0.1228676   0.040  0.96822
z.diff.lag2 -0.2502515  0.1150603  -2.175  0.03306 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.002562 on 69 degrees of freedom
Multiple R-squared:  0.285,    Adjusted R-squared:  0.2539
F-statistic: 9.168 on 3 and 69 DF,  p-value: 0.00003478

Value of test-statistic is: -3.0481 4.6668

Critical values for test statistics:
      1pct  5pct 10pct
tau2 -3.51 -2.89 -2.58
phi1  6.70  4.71  3.86

[adf.test] (contraste con mismo k)

      Augmented Dickey-Fuller Test

data: x
Dickey-Fuller = -1.2429, Lag order = 9, p-value = 0.8862
alternative hypothesis: stationary

==== ADF(auto) :: d_UNRATE (Δ desempleo) ====
Determinístico: drift | Criterio: BIC | Lag óptimo: 9

#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####

Test regression drift

Call:
lm(formula = z.diff ~ z.lag.1 + 1 + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-0.97194 -0.01612 -0.00294  0.02595  0.35783

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  0.002936  0.020019   0.147  0.8838
z.lag.1      -0.220521  0.102452  -2.152  0.0349 *
z.diff.lag1 -0.146128  0.124275  -1.176  0.2437
z.diff.lag2 -0.255277  0.116507  -2.191  0.0318 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.1674 on 69 degrees of freedom
Multiple R-squared:  0.2149,    Adjusted R-squared:  0.1808
F-statistic: 6.297 on 3 and 69 DF,  p-value: 0.000771

Value of test-statistic is: -2.1524 2.3587

Critical values for test statistics:
      1pct  5pct 10pct
tau2 -3.51 -2.89 -2.58
phi1  6.70  4.71  3.86

[adf.test] (contraste con mismo k)

      Augmented Dickey-Fuller Test

data: x
Dickey-Fuller = -1.9813, Lag order = 9, p-value = 0.5835
alternative hypothesis: stationary

```

```

==== ADF(auto) :: dlog_INDPRO (crec. ind.) ====
Determinístico: drift | Criterio: BIC | Lag óptimo: 9

#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####

Test regression drift

Call:
lm(formula = z.diff ~ z.lag.1 + 1 + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-0.130821 -0.004940  0.002409  0.006075  0.038252

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.0001464  0.0023105  -0.063  0.94964
z.lag.1      -1.0853325  0.1444161  -7.515 0.000000000142 ***
z.diff.lag   0.3301124  0.1130913   2.919  0.00472 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.01974 on 70 degrees of freedom
Multiple R-squared:  0.4715,    Adjusted R-squared:  0.4564
F-statistic: 31.22 on 2 and 70 DF,  p-value: 0.0000000002028

Value of test-statistic is: -7.5153 28.2416

Critical values for test statistics:
      1pct  5pct 10pct
tau2 -3.51 -2.89 -2.58
phi1  6.70  4.71  3.86

[adf.test] (contraste con mismo k)

      Augmented Dickey-Fuller Test

data: x
Dickey-Fuller = -2.9682, Lag order = 9, p-value = 0.1789
alternative hypothesis: stationary

==== ADF(auto) :: d_UNRATE (Δ desempleo) ====
Determinístico: drift | Criterio: BIC | Lag óptimo: 9

#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####

Test regression drift

Call:
lm(formula = z.diff ~ z.lag.1 + 1 + z.diff.lag)

Residuals:
    Min       1Q   Median       3Q      Max
-2.1021 -0.1922 -0.0768  0.0812 10.3686

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  0.004801  0.153585   0.031  0.975
z.lag.1      -1.126236  0.166332  -6.771 0.000000000326 ***
z.diff.lag   0.140234  0.118347   1.185  0.240
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 1.312 on 70 degrees of freedom
Multiple R-squared:  0.5038,    Adjusted R-squared:  0.4896
F-statistic: 35.54 on 2 and 70 DF,  p-value: 0.00000000002229

Value of test-statistic is: -6.771 22.9233

Critical values for test statistics:
      1pct  5pct 10pct
tau2 -3.51 -2.89 -2.58
phi1  6.70  4.71  3.86

[adf.test] (contraste con mismo k)

      Augmented Dickey-Fuller Test

data: x
Dickey-Fuller = -3.3203, Lag order = 9, p-value = 0.07403
alternative hypothesis: stationary

```

## Salidas KPSS y ERS/ADF-GLS sobre transformaciones

```
==== KPSS :: dlog_SP500 (H0: estacionario en nivel) ====

      KPSS Test for Level Stationarity

data: x
KPSS Level = 0.12293, Truncation lag parameter = 3, p-value = 0.1
```

```
==== ERS-DGGLS :: dlog_SP500 | modelo: const | p=9 ====
```

```
#####
# Elliot, Rothenberg and Stock Unit Root Test #
#####
```

```
Test of type DF-GLS
detrending of series with intercept
```

```
Call:
lm(formula = dfgls.form, data = data.dfgls)
```

```
Residuals:
      Min       1Q   Median       3Q      Max
-0.20517 -0.01722  0.01064  0.02884  0.07288
```

Coefficients:

|              | Estimate | Std. Error | t value | Pr(> t )   |
|--------------|----------|------------|---------|------------|
| yd.lag       | -0.1458  | 0.1947     | -0.749  | 0.45663    |
| yd.diff.lag1 | -0.7163  | 0.2183     | -3.281  | 0.00169 ** |
| yd.diff.lag2 | -0.7550  | 0.2299     | -3.284  | 0.00168 ** |
| yd.diff.lag3 | -0.7369  | 0.2414     | -3.053  | 0.00332 ** |
| yd.diff.lag4 | -0.6742  | 0.2426     | -2.779  | 0.00718 ** |
| yd.diff.lag5 | -0.5298  | 0.2391     | -2.215  | 0.03037 *  |
| yd.diff.lag6 | -0.4661  | 0.2221     | -2.099  | 0.03985 *  |
| yd.diff.lag7 | -0.2184  | 0.1985     | -1.100  | 0.27543    |
| yd.diff.lag8 | -0.1468  | 0.1644     | -0.893  | 0.37543    |
| yd.diff.lag9 | -0.1325  | 0.1245     | -1.064  | 0.29139    |

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 0.04368 on 63 degrees of freedom
Multiple R-squared:  0.4638,    Adjusted R-squared:  0.3787
F-statistic:  5.45 on 10 and 63 DF,  p-value: 0.000008852
```

Value of test-statistic is: -0.749

Critical values of DF-GLS are:

```
      1pct  5pct 10pct
critical values -2.59 -1.94 -1.62
```

```
==== KPSS :: dlog_CPIAUCSL (H0: estacionario en nivel) ====
```

```
      KPSS Test for Level Stationarity
```

```
data: x
KPSS Level = 0.40965, Truncation lag parameter = 3, p-value = 0.073
```

```
==== ERS-DGGLS :: dlog_CPIAUCSL | modelo: const | p=9 ====
```

```
#####
# Elliot, Rothenberg and Stock Unit Root Test #
#####
```

```
Test of type DF-GLS
detrending of series with intercept
```

```
Call:
lm(formula = dfgls.form, data = data.dfgls)
```

```
Residuals:
      Min       1Q   Median       3Q      Max
-0.0078588 -0.0007831  0.0000941  0.0012614  0.0052654
```

Coefficients:

|              | Estimate | Std. Error | t value | Pr(> t ) |
|--------------|----------|------------|---------|----------|
| yd.lag       | -0.20861 | 0.14587    | -1.430  | 0.1576   |
| yd.diff.lag1 | -0.14032 | 0.17108    | -0.820  | 0.4152   |
| yd.diff.lag2 | -0.44196 | 0.17016    | -2.597  | 0.0117 * |
| yd.diff.lag3 | -0.20645 | 0.17806    | -1.159  | 0.2506   |
| yd.diff.lag4 | -0.31756 | 0.17081    | -1.859  | 0.0677 . |
| yd.diff.lag5 | -0.13655 | 0.17044    | -0.801  | 0.4260   |
| yd.diff.lag6 | -0.27847 | 0.15921    | -1.749  | 0.0851 . |
| yd.diff.lag7 | 0.03198  | 0.15406    | 0.208   | 0.8362   |
| yd.diff.lag8 | -0.03227 | 0.13108    | -0.246  | 0.8063   |
| yd.diff.lag9 | -0.17089 | 0.12223    | -1.398  | 0.1670   |

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 0.002479 on 63 degrees of freedom
Multiple R-squared:  0.389,    Adjusted R-squared:  0.2921
F-statistic: 4.012 on 10 and 63 DF,  p-value: 0.0002829
```

Value of test-statistic is: -1.4301

Critical values of DF-GLS are:

```
      1pct  5pct 10pct
critical values -2.59 -1.94 -1.62
```

```
==== KPSS :: dlog_NASDAQ (H0: estacionario en nivel) ====
```

```
      KPSS Test for Level Stationarity
```

```
data: x
KPSS Level = 0.094879, Truncation lag parameter = 3, p-value = 0.1
```

```
==== ERS-DGGLS :: dlog_NASDAQ | modelo: const | p=9 ====
```

```
#####
# Elliot, Rothenberg and Stock Unit Root Test #
#####
```

```
Test of type DF-GLS
detrending of series with intercept
```

```
Call:
lm(formula = dfgls.form, data = data.dfgls)
```

```
Residuals:
      Min       1Q   Median       3Q      Max
-0.17335 -0.01935  0.01430  0.03895  0.09258
```

Coefficients:

|              | Estimate | Std. Error | t value | Pr(> t ) |
|--------------|----------|------------|---------|----------|
| yd.lag       | -0.39374 | 0.25879    | -1.521  | 0.1332   |
| yd.diff.lag1 | -0.43400 | 0.26248    | -1.653  | 0.1032   |
| yd.diff.lag2 | -0.46395 | 0.25967    | -1.787  | 0.0788 . |
| yd.diff.lag3 | -0.44364 | 0.25740    | -1.724  | 0.0897 . |
| yd.diff.lag4 | -0.35660 | 0.24837    | -1.436  | 0.1560   |
| yd.diff.lag5 | -0.26450 | 0.23635    | -1.119  | 0.2674   |
| yd.diff.lag6 | -0.23491 | 0.21814    | -1.077  | 0.2857   |
| yd.diff.lag7 | -0.05287 | 0.19352    | -0.273  | 0.7856   |
| yd.diff.lag8 | -0.03872 | 0.16232    | -0.239  | 0.8122   |
| yd.diff.lag9 | -0.05974 | 0.12486    | -0.478  | 0.6340   |

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 0.05153 on 63 degrees of freedom
Multiple R-squared:  0.4386,    Adjusted R-squared:  0.3495
F-statistic: 4.922 on 10 and 63 DF,  p-value: 0.00003061
```

Value of test-statistic is: -1.5214

Critical values of DF-GLS are:

```
      1pct  5pct 10pct
critical values -2.59 -1.94 -1.62
```

```
==== KPSS :: dlog_INDPRO (H0: estacionario en nivel) ====
```

```
      KPSS Test for Level Stationarity
```

```
data: x
KPSS Level = 0.048472, Truncation lag parameter = 3, p-value = 0.1
```

```
==== ERS-DGGLS :: dlog_INDPRO | modelo: const | p=9 ====
```

```
#####
# Elliot, Rothenberg and Stock Unit Root Test #
#####
```

```
Test of type DF-GLS
detrending of series with intercept
```

```
Call:
lm(formula = dfgls.form, data = data.dfgls)
```

```
Residuals:
      Min       1Q   Median       3Q      Max
-0.133491 -0.007288 -0.000969  0.004811  0.035715
```

Coefficients:

|              | Estimate  | Std. Error | t value | Pr(> t ) |
|--------------|-----------|------------|---------|----------|
| yd.lag       | -1.228434 | 0.470146   | -2.613  | 0.0112 * |
| yd.diff.lag1 | 0.457853  | 0.439737   | 1.041   | 0.3018   |
| yd.diff.lag2 | 0.135493  | 0.407524   | 0.332   | 0.7406   |
| yd.diff.lag3 | 0.098315  | 0.375195   | 0.262   | 0.7941   |
| yd.diff.lag4 | -0.007757 | 0.337967   | -0.023  | 0.9818   |
| yd.diff.lag5 | -0.038597 | 0.297793   | -0.130  | 0.8973   |
| yd.diff.lag6 | -0.063767 | 0.253447   | -0.252  | 0.8022   |
| yd.diff.lag7 | -0.039366 | 0.208893   | -0.188  | 0.8511   |
| yd.diff.lag8 | -0.158338 | 0.157490   | -1.005  | 0.3186   |
| yd.diff.lag9 | -0.115797 | 0.124775   | -0.928  | 0.3569   |

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 0.0204 on 63 degrees of freedom
Multiple R-squared:  0.4921,    Adjusted R-squared:  0.4115
F-statistic: 6.105 on 10 and 63 DF,  p-value: 0.000001998
```

Value of test-statistic is: -2.6129

Critical values of DF-GLS are:

```
      1pct  5pct 10pct
critical values -2.59 -1.94 -1.62
```

```
==== KPSS :: d_EFFR (H0: estacionario en nivel) ====

      KPSS Test for Level Stationarity

data: x
KPSS Level = 0.28503, Truncation lag parameter = 3, p-value = 0.1
```

```
==== ERS-DGLS :: d_EFFR | modelo: const | p=9 ====
```

```
#####
# Elliot, Rothenberg and Stock Unit Root Test #
#####
```

```
Test of type DF-GLS
detrending of series with intercept
```

```
Call:
lm(formula = dfgls.form, data = data.dfgls)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-0.91725 -0.03739  0.00609  0.04768  0.36903
```

```
Coefficients:
            Estimate Std. Error t value Pr(>|t|)
yd.lag      -0.25769    0.12468  -2.067   0.0429 *
yd.diff.lag1 -0.11077    0.15387  -0.720   0.4742
yd.diff.lag2 -0.28268    0.15221  -1.857   0.0680 .
yd.diff.lag3  0.03040    0.15632   0.194   0.8464
yd.diff.lag4 -0.06759    0.15625  -0.433   0.6668
yd.diff.lag5  0.21470    0.15615   1.375   0.1740
yd.diff.lag6  0.10610    0.15278   0.694   0.4899
yd.diff.lag7  0.20829    0.14959   1.392   0.1687
yd.diff.lag8  0.06567    0.13395   0.490   0.6257
yd.diff.lag9  0.13306    0.12375   1.075   0.2864
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 0.169 on 63 degrees of freedom
Multiple R-squared:  0.2693, Adjusted R-squared:  0.1533
F-statistic: 2.322 on 10 and 63 DF, p-value: 0.02131
```

```
Value of test-statistic is: -2.0667
```

```
Critical values of DF-GLS are:
      1pct 5pct 10pct
critical values -2.59 -1.94 -1.62
```

```
==== KPSS :: d_UNRATE (H0: estacionario en nivel) ====

      KPSS Test for Level Stationarity

data: x
KPSS Level = 0.043008, Truncation lag parameter = 3, p-value = 0.1
```

```
==== ERS-DGLS :: d_UNRATE | modelo: const | p=9 ====
```

```
#####
# Elliot, Rothenberg and Stock Unit Root Test #
#####
```

```
Test of type DF-GLS
detrending of series with intercept
```

```
Call:
lm(formula = dfgls.form, data = data.dfgls)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-1.4144 -0.4029 -0.1919 -0.0355 10.3017
```

```
Coefficients:
            Estimate Std. Error t value Pr(>|t|)
yd.lag      -1.76978    0.53827  -3.288   0.00165 **
yd.diff.lag1  0.75834    0.50193   1.511   0.13583
yd.diff.lag2  0.57498    0.46395   1.239   0.21982
yd.diff.lag3  0.52493    0.42145   1.246   0.21754
yd.diff.lag4  0.35059    0.37622   0.932   0.35496
yd.diff.lag5  0.29054    0.32996   0.881   0.38192
yd.diff.lag6  0.17169    0.27989   0.613   0.54182
yd.diff.lag7  0.12457    0.23297   0.535   0.59475
yd.diff.lag8  0.07029    0.17875   0.393   0.69549
yd.diff.lag9  0.04477    0.12573   0.356   0.72300
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 1.357 on 63 degrees of freedom
Multiple R-squared:  0.5225, Adjusted R-squared:  0.4468
F-statistic: 6.895 on 10 and 63 DF, p-value: 0.000000358
```

```
Value of test-statistic is: -3.2879
```

```
Critical values of DF-GLS are:
      1pct 5pct 10pct
critical values -2.59 -1.94 -1.62
```

## Salida prueba Engle-Granger

```
Engle-Granger (OLS en niveles) SP500 ~ INDPRO + CPI + EFFR + UNRATE

Call:
lm(formula = SP500 ~ INDPRO + CPIAUSL + EFFR + UNRATE, data = df_lv1)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-892.9 -194.8  19.2  232.2  775.0
```

```
Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -9489.102   4926.049  -1.926   0.0577 .
INDPRO      12.832     44.332    0.289   0.7730
CPIAUSL      44.371     2.616   16.958 < 0.0000000000000002 ***
EFFR       -169.364    35.088   -4.827   0.00000665 ***
UNRATE      19.561     71.537    0.273   0.7852
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 380.8 on 79 degrees of freedom
Multiple R-squared:  0.837, Adjusted R-squared:  0.8287
F-statistic: 101.4 on 4 and 79 DF, p-value: < 0.00000000000000022
```

```
==== ADF(auto) :: EG residuales ====
Determinístico: none | Criterio: BIC | Lag óptimo: 9
```

```
==== ADF(auto) :: EG residuales ====
Determinístico: none | Criterio: BIC | Lag óptimo: 9
```

```
#####
# Augmented Dickey-Fuller Test Unit Root Test #
#####
```

```
Test regression none
```

```
Call:
lm(formula = z.diff ~ z.lag.1 - 1 + z.diff.lag)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-687.53 -62.86  50.25  105.69  278.73
```

```
Coefficients:
            Estimate Std. Error t value Pr(>|t|)
z.lag.1      -0.07042    0.04850  -1.452   0.151
z.diff.lag    0.14408    0.11970   1.204   0.233
```

```
Residual standard error: 153.7 on 72 degrees of freedom
Multiple R-squared:  0.03769, Adjusted R-squared:  0.01096
F-statistic: 1.41 on 2 and 72 DF, p-value: 0.2508
```

```
Value of test-statistic is: -1.452
```

```
Critical values for test statistics:
      1pct 5pct 10pct
tau1 -2.6 -1.95 -1.61
```

```
[adf.test] (contraste con mismo k)
```

```
Augmented Dickey-Fuller Test
```

```
data: x
Dickey-Fuller = -2.1472, Lag order = 9, p-value = 0.5155
alternative hypothesis: stationary
```

## Diagnósticos de validez para el modelo S&P 500 y NASDAQ 100 en el segmento “PRE”

```
-- BG(1):
      Breusch-Godfrey test for serial correlation of order up to 1
data: m
LM test = 0.52636, df = 1, p-value = 0.4681

-- BG(3):
      Breusch-Godfrey test for serial correlation of order up to 3
data: m
LM test = 1.4464, df = 3, p-value = 0.6947

-- White:
      studentized Breusch-Pagan test
data: m
BP = 5.5884, df = 2, p-value = 0.06116

-- BP:
      studentized Breusch-Pagan test
data: m
BP = 9.3168, df = 4, p-value = 0.05365

-- RESET:
      RESET test
data: m
RESET = 2.7322, df1 = 2, df2 = 18, p-value = 0.092

-- JB:
      Jarque Bera Test
data: residuals(m)
X-squared = 0.99329, df = 2, p-value = 0.6086

-- VIF:
      d_EFFR_BASE_1 dlog_CPIAUCSL_1 dlog_INDPRO_1 d_UNRATE_1
      1.000000      1.042872      1.054361      1.012522
```

```
-- BG(1):
      Breusch-Godfrey test for serial correlation of order up to 1
data: m
LM test = 0.12883, df = 1, p-value = 0.7196

-- BG(3):
      Breusch-Godfrey test for serial correlation of order up to 3
data: m
LM test = 0.96495, df = 3, p-value = 0.8097

-- White:
      studentized Breusch-Pagan test
data: m
BP = 7.596, df = 2, p-value = 0.02242

-- BP:
      studentized Breusch-Pagan test
data: m
BP = 11.422, df = 4, p-value = 0.02221

-- RESET:
      RESET test
data: m
RESET = 3.1008, df1 = 2, df2 = 18, p-value = 0.06964

-- JB:
      Jarque Bera Test
data: residuals(m)
X-squared = 0.53176, df = 2, p-value = 0.7665

-- VIF:
      d_EFFR_BASE_1 dlog_CPIAUCSL_1 dlog_INDPRO_1 d_UNRATE_1
      1.000000      1.042872      1.054361      1.012522
```

## Diagnósticos de validez para el modelo S&P 500 y NASDAQ 100 en el segmento “COVID”

```
-- BG(1):
      Breusch-Godfrey test for serial correlation of order up to 1
```

```
data: m
LM test = 0.29363, df = 1, p-value = 0.5879
```

```
-- BG(3):
      Breusch-Godfrey test for serial correlation of order up to 3
```

```
data: m
LM test = 8.6152, df = 3, p-value = 0.03487
```

```
-- White:
      studentized Breusch-Pagan test
```

```
data: m
BP = 3.554, df = 2, p-value = 0.1691
```

```
-- BP:
      studentized Breusch-Pagan test
```

```
data: m
BP = 4.8817, df = 5, p-value = 0.4305
```

```
-- RESET:
      RESET test

data: m
RESET = 1.3217, df1 = 2, df2 = 12, p-value = 0.3028
```

```
-- JB:
      Jarque Bera Test
```

```
data: residuals(m)
X-squared = 0.8227, df = 2, p-value = 0.6628
```

```
-- VIF:
d_EFFR_ZLB_1 dlog_CPIAUCSL_1 dlog_INDPRO_1 d_UNRATE_1 y_L1
1.094810 1.225433 2.251113 2.170131 1.279035
```

```
-- BG(1):
      Breusch-Godfrey test for serial correlation of order up to 1
```

```
data: m
LM test = 1.6785, df = 1, p-value = 0.1951
```

```
-- BG(3):
      Breusch-Godfrey test for serial correlation of order up to 3
```

```
data: m
LM test = 2.7838, df = 3, p-value = 0.4262
```

```
-- White:
      studentized Breusch-Pagan test
```

```
data: m
BP = 2.178, df = 2, p-value = 0.3365
```

```
-- BP:
      studentized Breusch-Pagan test
```

```
data: m
BP = 6.4474, df = 5, p-value = 0.2651
```

```
-- RESET:
      RESET test

data: m
RESET = 0.10269, df1 = 2, df2 = 13, p-value = 0.9031
```

```
-- JB:
      Jarque Bera Test
```

```
data: residuals(m)
X-squared = 6.6077, df = 2, p-value = 0.03674
```

```
-- VIF:
d_EFFR_ZLB_1 dlog_CPIAUCSL_1 dlog_INDPRO_1 d_UNRATE_1 D_2020m04
136.920120 29.140270 9.238688 2.417107 188.053591
```

## Diagnósticos de validez para el modelo S&P 500 y NASDAQ 100 en el segmento “POST”

```
-- BG(1):

Breusch-Godfrey test for serial correlation of order up to 1

data: m
LM test = 0.94989, df = 1, p-value = 0.3297
```

```
-- BG(3):

Breusch-Godfrey test for serial correlation of order up to 3

data: m
LM test = 1.5625, df = 3, p-value = 0.6679
```

```
-- White:

studentized Breusch-Pagan test

data: m
BP = 2.1117, df = 2, p-value = 0.3479
```

```
-- BP:

studentized Breusch-Pagan test

data: m
BP = 5.7536, df = 5, p-value = 0.3309
```

```
-- RESET:

RESET test

data: m
RESET = 0.13129, df1 = 2, df2 = 28, p-value = 0.8775
```

```
-- JB:

Jarque Bera Test

data: residuals(m)
X-squared = 1.56, df = 2, p-value = 0.4584
```

```
-- VIF:
d_EFFR_HIKING_1 d_EFFR_PLATEAU_1 dlog_CPIAUCSL_1 dlog_INDPRO_1 d_UNRATE_1
1.056749 1.056749 1.092104 1.075065 1.022019
```

```
-- BG(1):

Breusch-Godfrey test for serial correlation of order up to 1

data: m
LM test = 0.0010498, df = 1, p-value = 0.9742
```

```
-- BG(3):

Breusch-Godfrey test for serial correlation of order up to 3

data: m
LM test = 0.10984, df = 3, p-value = 0.9906
```

```
-- White:

studentized Breusch-Pagan test

data: m
BP = 3.6638, df = 2, p-value = 0.1601
```

```
-- BP:

studentized Breusch-Pagan test

data: m
BP = 4.0302, df = 5, p-value = 0.5451
```

```
-- RESET:

RESET test

data: m
RESET = 0.5473, df1 = 2, df2 = 28, p-value = 0.5846
```

```
-- JB:

Jarque Bera Test

data: residuals(m)
X-squared = 0.27316, df = 2, p-value = 0.8723
```

```
-- VIF:
d_EFFR_HIKING_1 d_EFFR_PLATEAU_1 dlog_CPIAUCSL_1 dlog_INDPRO_1 d_UNRATE_1
1.056749 1.056749 1.092104 1.075065 1.022019
```

# Referencias

- Bernanke, B. S., & Gertler, M. (1999). *Monetary policy and asset price volatility*. Federal Reserve Bank of Kansas City Economic Review, 84(4), 17–51.
- Bernanke, B. S., & Kuttner, K. N. (2005). *What explains the stock market's reaction to Federal Reserve policy?* Journal of Finance, 60(3), 1221–1257.  
<https://doi.org/10.1111/j.1540-6261.2005.00760.x>
- Blinder, A. S., & Reis, R. (2022). *Understanding the Powell Shock: Monetary Policy, Inflation, and Communication*. Princeton University Press.
- Campbell, J. R., Evans, C. L., Fisher, J. D. M., & Justiniano, A. (2012). *Macroeconomic effects of Federal Reserve forward guidance*. Brookings Papers on Economic Activity, 43(1), 1–54.
- Ehrmann, M., & Fratzscher, M. (2004). *Taking stock: Monetary policy transmission to equity markets*. Journal of Money, Credit and Banking, 36(4), 719–737.  
<https://doi.org/10.1353/mcb.2004.0047>
- Federal Reserve Bank of New York. (s. f.). *Effective Federal Funds Rate (EFFR)*.  
<https://www.newyorkfed.org/markets/reference-rates/effr>
- Ireland, P. N. (2006). *The monetary transmission mechanism*. Federal Reserve Bank of Boston, Working Paper 06-1.
- Jordà, Ò., Schularick, M., & Taylor, A. M. (2020). *The effects of quasi-random monetary experiments*. American Economic Journal: Macroeconomics, 12(1), 1–43.
- Kashyap, A. K., & Stein, J. C. (2023). *The monetary transmission mechanism: Recent developments and lessons for policy*. Journal of Economic Perspectives, 37(2), 21–46.

- Kuttner, K. N., & Mosser, P. C. (2002). *The monetary transmission mechanism: Some answers and further questions*. Federal Reserve Bank of New York Economic Policy Review, 8(1), 15–26.
- Mishkin, F. S. (2019). *The economics of money, banking and financial markets* (12th ed.). Pearson Education.
- Miranda-Agrippino, S., & Ricco, G. (2021). *The transmission of monetary policy shocks*. American Economic Journal: Macroeconomics, 13(3), 74–107.
- Neuhierl, A., & Weber, M. (2019). *Monetary policy and the stock market: Time-series evidence*. Journal of Monetary Economics, 108, 157–170.
- Rigobon, R., & Sack, B. (2004). *The impact of monetary policy on asset prices*. Journal of Monetary Economics, 51(8), 1553–1575.
- Stock, J. H., & Watson, M. W. (2012). *Introduction to econometrics* (3rd ed.). Pearson Education.