

Universidad Andina Simón Bolívar

Sede Ecuador

Área de Gestión

Maestría en Gestión Financiera y Administración de Riesgos Financieros

Análisis de quiebres y recuperación de precios de las acciones de las principales empresas que cotizan en la Bolsa de Valores de Quito para el periodo 2019-2022 y su relación con el COVID-19 mediante la implementación del algoritmo BFAST

Yusleidy Carolina Quintero Durán

Tutora: Alexander Andrade

Quito, 2024

Trabajo almacenado en el Repositorio Institucional UASB-DIGITAL con licencia Creative Commons 4.0 Internacional

	Reconocimiento de créditos de la obra No comercial Sin obras derivadas	
---	---	---

Para usar esta obra, deben respetarse los términos de esta licencia

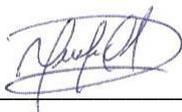
Cláusula de cesión de derecho de publicación

Yo, Yusleidy Carolina Quintero Durán, autora de la tesis intitulada “Análisis de quiebres y recuperación de precios de las acciones de las principales empresas que cotizan en la Bolsa de Valores de Quito para el periodo 2019-2022 y su relación con el COVID-19 mediante la implementación del algoritmo BFAST”, mediante el presente documento dejo constancia de que la obra es de mi exclusiva autoría y producción, que la he elaborado para cumplir con uno de los requisitos previos para la obtención del título de Magíster en Gestión Financiera y Administración de Riesgos Financieros en la Universidad Andina Simón Bolívar, Sede Ecuador.

1. Cedo a la Universidad Andina Simón Bolívar, Sede Ecuador, los derechos exclusivos de reproducción, comunicación pública, distribución y divulgación, durante 36 meses a partir de mi graduación, pudiendo por lo tanto la Universidad, utilizar y usar esta obra por cualquier medio conocido o por conocer, siempre y cuando no se lo haga para obtener beneficio económico. Esta autorización incluye la reproducción total o parcial en los formatos virtual, electrónico, digital, óptico, como usos en red local y en internet.
2. Declaro que en caso de presentarse cualquier reclamación de parte de terceros respecto de los derechos de autor/a de la obra antes referida, yo asumiré toda responsabilidad frente a terceros y a la Universidad.
3. En esta fecha entrego a la Secretaría General, el ejemplar respectivo y sus anexos en formato impreso y digital o electrónico.

21 de junio de 2024

Firma: _____



Resumen

En el presente trabajo se seleccionó 10 empresas que cotizan en la Bolsa de Valores de Quito para explorar el impacto en el precio debido al COVID-19. Para realizar el estudio, las 10 empresas se agruparon en 2 grupos de acuerdo con su actividad económica (sector financiero, productivo y comercial). Se definieron tres ventanas temporales, PRE-COVID (enero - diciembre de 2019), COVID (enero a diciembre 2020), y POST-COVID (enero 2021 - diciembre 2022), para identificar el momento y las condiciones del impacto. Las anomalías, ocasionadas por el COVID-19, fueron evaluadas a partir de la detección de quiebres mediante el algoritmo BFAST, y con fines comparativos se utilizó el algoritmo CUSUM.

Los análisis realizados indican que el COVID-19 generó impactos diferentes entre los sectores financieros, comercial y productivo. BFAST demostró una mayor potencialidad para el análisis realizado, debido a que los quiebres estructurales detectados por este algoritmo estuvieron mayormente vinculados a cambios de tendencias, que aquellos detectados mediante el algoritmo CUSUM. De modo similar, BFAST permitió una caracterización más ajustada a los datos observados, sobre el impacto y la recuperación del precio medio mensual de las acciones, considerando el periodo COVID, y el periodo POST-COVID.

Palabras clave: BFAST, CUSUM, quiebres estructurales, mercado de valores, bolsa de valores de Quito, series temporales, Covid-19

Tabla de contenidos

Figuras y tablas.....	9
Abreviaturas.....	11
Introducción.....	13
Capítulo primero Marco teórico	19
1. Estado del arte	19
1.1. Impacto de la pandemia del COVID-19 en el precio de las acciones.....	19
1.2. La influencia de eventos mundiales en los precios de acciones.....	23
1.3. Análisis de efectos de eventos mundiales en el precio de acciones.....	24
2. Fundamentos teóricos.....	31
2.1. El algoritmo BFAST	32
Capítulo segundo Marco empírico	35
1. Fuentes de información	35
2. Enfoque de procesamiento	35
3. Metodología de la investigación.....	36
3.1 Diseño del Estudio	37
3.2. Definición del periodo temporal del estudio	39
Capítulo tercero Análisis de resultados	47
1. Resultados de la etapa de Pre-procesamiento de los datos.....	47
1.1 main.py.....	47
1.2 Interpolador.py	49
1.3 Fusion.py.....	49
2. Detección de Quiebres Estructurales.....	49
2.1. Estadística Descriptiva	50
2.2. Detección de Quiebres para el periodo 2019-2022	50

3. Análisis de Anomalías y Recuperación de Precios de Cotización a Consecuencia del COVID-19	60
3.1. Anomalías y Recuperación de Precios en el Sector Financiero	60
3.2. Anomalías y Recuperación de Precios en el Sector Productivo y Comercial	61
Capítulo cuarto Discusión de Resultados	63
1. Impacto ocasionado por el COVID-19	63
2. Recuperación en fase POST-COVID	64
3. Comparación de los resultados obtenidos	64
Conclusiones y recomendaciones	71
Obras citadas	75
Anexos	83
Anexo 1: Script main.py	83
Anexo 2: Script Interpolador.py	91
Anexo 3: Script Fusion.py	92
Anexo 4: Código BFAST	94
Anexo 5: Código CUSUM	96

Figuras y tablas

Figura 1. Retornos acumulados durante la fase PRE-COVID, y los meses iniciales de la etapa COVID.....	20
Figura 2. Pronósticos del Producto Interno Bruto, tomando como línea base los niveles PRE-COVID, para los Estados Unidos y el Mercado Global.	21
Figura 3. Valor de cotización del S&P500 durante el periodo marzo 2016 a marzo 2020.	22
Figura 4. Desempeño de las principales bolsas de valores del mundo durante 2020.....	23
Figura 5. Componentes de análisis de series temporales identificados mediante el algoritmo BFAST	33
Figura 6. Análisis de anomalías de series temporales mediante el algoritmo BFAST... ..	34
Figura 7. Diseño de estudio	37
Figura 8. Resultados de quiebres para el sector financiero mediante CUSUM..	54
Figura 9. Resultados de quiebres para el sector financiero mediante BFAST.	55
Figura 10. Resultados de quiebres para el sectores productivos y comercial mediante CUSUM.....	57
Figura 11. Resultados de quiebres para el sectores productivos y comercial mediante BFAST.....	59
Figura 12. Índices Bursátiles de un subconjunto de países en Latinoamérica, bajo la influencia del periodo inicial del COVID-19	66
Figura 13. Índice de Volatilidad de Mercados (VIX).....	66
Figura 14. Quiebres estructurales detectados en el coeficiente de correlación de Kendall para futuros de petróelos y mercado de valores NDQA de los Estados Unidos.	68
Tabla 1 Empresas por número de meses con cotización en la BVQ desde enero 2013 hasta diciembre de 2022	49
Tabla 2 Estadística descriptiva del precio de cotización de acciones durante los periodos PRE-COVID (2019), COVID (2020) y POST-COVID (2021-2022)	51

Abreviaturas

BFAST: Detección de Quiebres por Tendencias y Estacionalidades Aditivas

BVG: Bolsa de Valores de Guayaquil

BVQ: Bolsa de Valores de Quito

COE: Comité de Operaciones de Emergencia del Ecuador

CUSUM: Cambios estructurales con series cuadradas de Suma Cumulativa

FED: Fondo de la Reserva Federal (USA)

FFR: Tasa de los Fondos Federales (USA)

MBN: Mercado Bursátil Nacional

MOSUM: Suma de Medias Móviles

NYSE: Bolsa de Valores de New York

QE: Quiebre Estructural

Introducción

La pandemia provocada por el COVID-19 está asociada con importantes efectos negativos en el sector financiero, a escala global (De los Baños y Roldán-Casas 2021), regional (Mendoza-Rivera, Lozano-Díez, y Venegas-Martínez 2020), (Alzúa y Gosis 2020) (Huamán 2021), y nacional (Ceballos-Palma, Bermeo-Pazmiño, y Vásconez-Acuña 2020), (Huilcapi, Troya, y Ocampo 2020), (Jumbo et al. 2020). Estos efectos, aunados a los diferentes aspectos de carácter global que tienen influencia directa o indirecta sobre los mercados financieros más importantes del mundo, han propiciado las condiciones para una caída sostenida de los mercados de valores internacionales desde 2020, y que aún persiste en 2022 (Li et al. 2022). Las consecuencias de estas presiones sobre los mercados de valores naturalmente tienen su influencia en los diferentes componentes de mercados de valores nacionales; como en el caso de la Bolsa de Valores de Quito (BVQ).

El Mercado Bursátil Nacional (MBN) está constituido por la Bolsa de Valores de Guayaquil (BVG) y la Bolsa de Valores de Quito (BVQ). Éstas, a su vez, negocian valores en renta fija como son Certificados de Inversión, Certificados de Depósitos, Certificados de Tesorería, entre otros. También, negocian valores en rentas variables como son Acciones de Empresas y Fondos de Inversiones (BVQ EC 2019). Particularmente, los precios de los activos financieros de renta variable están relacionados con el desempeño financiero y económico de las empresas emisoras, y son susceptibles a la volatilidad ocasionada por agentes exógenos que puedan influir en la oferta y la demanda (Binder y Merges 2001), tales como la pandemia del COVID-19.

En el sector financiero, es importante destacar el impacto del COVID-19 en el mercado de valores y particularmente en el mercado de acciones de los diferentes mercados de valores del mundo; tales como la Bolsa Valores de New York (NYSE), la Bolsa de Tokio, o la Bolsa de Londres. Trabajos previos han propuesto estudios para comprender el impacto ocasionado por el COVID-19 en bolsas de valores. Por ejemplo, Lee (2020) empleó técnicas de Big Data para explorar el impacto inicial de la pandemia en el mercado de valores de los Estados Unidos, y propuso técnicas de planificación de inversión en base a la generación de escenarios ocasionados por la pandemia. Análogamente, los autores Kamal, Ferdous y Hosain (2022), realizaron un

análisis de impacto del COVID-19 en acciones de bolsa de la industria pesquera marítima en los Estados Unidos, y entre los resultados reportados resalta el hecho de que las acciones de bolsa del sector reaccionan rápidamente a noticias relacionadas con la pandemia, y su nivel de intensidad depende de la gravedad de la noticia, así como también del tiempo de duración esperado de los efectos.

Otro resultado interesante en la literatura es el propuesto por Yousfi et al. (2021), en el que han identificado una correlación alta y extendida entre el mercado de valores de los Estados Unidos y las cantidades globales diarias de casos detectados y muertes ocasionadas por el COVID-19, confirmando resultados similares, en donde se vincula a los efectos de inseguridad e incertidumbres del mercado de valores de los Estados Unidos con los efectos generados por la pandemia del COVID-19 (Katafuchi, Kurita, y Managi 2020; Yoo y Managi 2020; Kurita y Managi 2022). A pesar de los hechos de que COVID-19 está dañando ferozmente al mundo con su brote, no llegando a un punto de inflexión, y que la línea de tiempo extranjera (casos fuera de china) todavía se está extendiendo; la evidencia de la cronología nacional (China) y la cronología de otros países, sugiere que COVID-19 tiene un impacto negativo, pero a corto plazo en las bolsas de valores de los países afectados (He et al. 2020).

En el Ecuador, Cadena, Pinargote y Solorzano (2018), presentaron un estudio detallado en el que se muestran evidencias sobre la importancia que tiene el mercado de valores nacional en el crecimiento de la economía. El autor afirma que los precios de cotización de las acciones de las principales empresas que cotizan en el mercado nacional están altamente relacionados con el precio de cotización del petróleo. Esta relación, sienta bases de referencias importantes, que facilita la comprensión de la dinámica del mercado de valores del Ecuador en la época pre y post COVID-19.

De acuerdo con reportes publicados por el Banco Central del Ecuador (BCE EC 2019) la Bolsa de Valores de Quito pasó de representar el 69% del Mercado Bursátil Nacional (MBN) para el 30 de diciembre del 2019, a un 40% para el 30 de septiembre de 2020. Esto representa una caída del 29% este periodo, que corresponde con la fase más restrictiva de movilidad adoptadas por el Comité de Operaciones de Emergencia (COE) del Ecuador. Esta disminución coincide con un decrecimiento del 66% del Volumen Nacional Negociado para la Renta Variable en el 2020 (BVQ EC 2022).

Como consecuencia de las restricciones gubernamentales para actividades comerciales y el distanciamiento social voluntario, operando en una economía orientada al servicio, el impacto de la pandemia del COVID-19 es considerado como el que más ha

afectado negativamente al mercado de acciones de los Estados Unidos en toda la historia (Baker et al. 2020). En este trabajo, Baker et al. utilizan series históricas de precios del mercado de acciones desde el año 1900 al 2020 (120 años), en conjunto con la volatilidad del mercado desde 1985 al 2020 (35 años), para comprobar, por una parte, que la pandemia COVID-19 ha sido el factor externo que más ha perjudicado al mercado de acciones, y, por otra parte, identificar factores potenciales que permitan explicar el fuerte impacto.

De forma similar, Mendoza-Rivera, Lozano-Díez, y Venegas-Martínez (2020) identificaron en un estudio que incluye varios países de Latinoamérica que entre los diferentes rasgos relacionados con la pandemia del COVID-19, el índice de letalidad impacta negativamente a los índices bursátiles y a las tasas de interés. En este trabajo, los autores destacan que la carencia de modelos predictivos diseñados para tratar con crisis de incertidumbres globales es uno de los factores que han agravado el impacto del COVID-19 en el mercado de acciones. Para esto, sugieren que el uso de modelos econométricos es indispensable para mitigar efectos de crisis globales en el futuro cercano.

En el contexto del Ecuador, es importante considerar que existen vínculos mensurables entre el mercado de valores nacional y el crecimiento de la economía ecuatoriana (Cadena, Pinargote, y Solorzano 2018). Los autores mencionan que el total de las negociaciones bursátiles en el Ecuador están dadas por la suma de las negociaciones de las bolsas de valores de Quito (BVQ) y Guayaquil (BVG). Vale destacar que los autores de este trabajo realizaron un análisis comparativo del ECUINDEX y del Índice Bursátil de New York (NYSE), destacando que, como consecuencia de la dolarización en el Ecuador, ambos índices tienen un comportamiento similar, con una correlación temporal relevante; lo que implica que las afectaciones observadas en el mercado de acciones de los Estados Unidos se esperan tengan impactos fenomenológicos similares en el mercado del Ecuador.

Con el objetivo de caracterizar el impacto generado por la pandemia COVID-19 en el mercado de valores del Ecuador, Maya Chávez (2022) realizó una investigación en el marco de una tesis de maestría, en la que analiza el impacto del COVID-19 en las 10 empresas principales que cotizan en la VBG tomando como referencia a ECUINDEX. Este estudio, basado en muestreo estadístico, implementado a partir de entrevistas a directivos de las empresas, y encuestas a expertos, permitió identificar el impacto percibido desde el punto de vista de las empresas, y de los expertos consultados.

Si bien este trabajo representa un antecedente pionero para caracterizar el impacto del COVID-19 en la VBG, el aporte tiene un enfoque cualitativo y con potencial sesgo en el juicio de expertos y la percepción organizacional de las empresas encuestadas. Por este motivo, para los fines de este trabajo, se considera la investigación de Verbesselt, Hyndman, Zeileis, et al. (2010) donde propone al algoritmo BFAST como un algoritmo novedoso para la detección de Quiebres y Anomalías asociadas a series temporales de datos. Este abordaje cuantitativo, se asocia con la posibilidad de establecer interconexiones, así como también establecer niveles de impacto y correlación, para una mejor caracterización del comportamiento de precios de las acciones de una selección de las empresas más importantes que cotizan en la BVQ; lo que permitirá evaluar la relación de las potenciales anomalías detectadas durante 2020, 2021, y 2022, con la pandemia del COVID-19.

En la actualidad, existen diversos enfoques metodológicos para estudiar los efectos que eventos socioeconómicos, geopolíticos, y epidemiológicos pueden causar en el mercado de valores internacional, y muy particularmente en el precio de las acciones de empresas que cotizan en las diferentes bolsas del mundo (Yousfi et al. 2021). Sin embargo, la mayoría de estas propuestas incluyen un enfoque holístico, en el que la necesidad de contar con datos muy específicos para su implementación termina siendo una limitación que dificultan su aplicación en muchos casos prácticos.

En este contexto, el uso de enfoques temporales, en el que los precios de las acciones pueden ser estudiados atendiendo exclusivamente al comportamiento de sus valores históricos, siguen siendo útiles; especialmente cuando el acceso a datos auxiliares que permitan explicar el dato con eventos que inciden sobre el precio, es escaso o inexistente. En este tipo de enfoques, se caracteriza la serie histórica del precio de las acciones, y luego en donde se detecten comportamientos atípicos, se procede a explicarlos mediante la correlación temporal que pueden tener con otras variables de interconexión asociadas a eventos influyentes.

El algoritmo de Quiebres por Estacionalidades y Tendencias Aditivas (BFAST, por sus siglas en inglés) fue propuesto por Verbesselt et. al (2010) para el análisis de series temporales de índices espectrales derivados de imágenes satelitales. Los autores resaltan, que una ventaja particular de BFAST, es la potencialidad que tiene para detectar anomalías en una serie temporal de datos, minimizando la probabilidad de detectar falsos positivos relacionados con tendencias y estacionalidades en los datos.

Naturalmente los efectos de incerteza y cambios que pueden tener lugar en un índice temporal de imágenes satelitales son diferentes a los que pueden influir en el precio de acciones del mercado de valores; sin embargo, es importante destacar que las alteraciones que puede haber en una serie histórica de precios de acciones presentan rasgos estadísticos y matemáticos que cumplen con los supuestos de detección del algoritmo BFAST. Estos supuestos incluyen la posibilidad de tener componentes estacionales y de tendencias en las series históricas, poder separar la serie de datos en históricos y de observación para fines de estudio, así como también comportamientos abruptos asociados a factores exógenos a la serie histórica de los datos.

El uso del algoritmo BFAST para el estudio del comportamiento de precio de acciones en la BVQ, a diferencia de utilizar modelos econométricos que requieren la disponibilidad de una gran cantidad de variables que permitan relacionar la serie histórica de precios con los efectos del COVID-19, o el uso de estadística descriptiva en el que se requiere un alto componente de interpretación para asociar los cambios con eventos disparadores, representa una oportunidad orientada a generar detecciones semiautomatizadas en los comportamientos de los precios de las acciones, debido a que este algoritmo genera alertas automáticas, en las que se definen los periodos de quiebres y anomalías en las series temporales.

En esta investigación de maestría, se utiliza el algoritmo BFAST para detectar quiebres estructurales ocasionados por el COVID-19 en las 10 principales empresas que cotizan en la Bolsa de Valores de Quito. Con la finalidad de comprender en detalle la correspondencia de los quiebres detectados con el COVID-19, el periodo de estudio ha sido analizado en tres fases: i) fase PRE-COVID que abarca desde el 1 de enero al 31 de diciembre de 2019, ii) la fase COVID que está comprendida desde el 1 de enero al 31 de diciembre de 2020, y iii) la fase POST-COVID que incluye el periodo que inicia el 1 de enero de 2021 y finaliza el 31 de diciembre de 2022.

Una novedad en el contexto de este trabajo, es la utilización del algoritmo BFAST para la detección de quiebres estructurales en series temporales financieras, particularmente en datos de mercado de valores. En este contexto, se ha seleccionado el algoritmo CUSUM para realizar comparaciones que permitan valorar las salidas generadas por BFAST. CUSUM se ha implementado a partir del paquete Strucchange de R.

El objetivo general es analizar quiebres y recuperación de precios de las acciones de las principales empresas que cotizan en la Bolsa de Valores de Quito para el periodo

2019-2022 y su relación con el COVID-19 mediante la implementación del algoritmo BFAST.

Para este fin se han definido los siguientes objetivos específicos: 1) Realizar una revisión literaria sobre enfoques y tendencias metodológicas para la caracterización de impactos en riesgo de mercado debido a la pandemia COVID-19 en empresas que cotizan en bolsas de valores. 2) Proponer un diseño metodológico para el estudio de quiebres y recuperación de precios de acciones de empresas en mercados de valores usando el algoritmo BFAST. 3) Aplicar el algoritmo BFAST a series temporales de precios de cotización para una selección de 10 empresas que coticen en la BVQ. 4) Analizar los eventos de detección de quiebres para el periodo 2019-2022 para las empresas seleccionadas. 5) Caracterizar el periodo post-COVID19 de los precios de cotización en las empresas cuyos precios de cotización hayan mostrado anomalías significativas, comparando los datos de observación con la tendencia generada por BFAST.

Este estudio se justifica porque el uso de algoritmos de detección de Quiebres Estructurales (QE) permiten conocer, en una serie temporal de datos, cambios abruptos que modifican de forma considerable la tendencia y estacionalidad de los datos de manera temporal. El algoritmo BFAST, además de permitir identificar los QE proporciona facilidades gráficas que pueden ser utilizadas para estimar el tiempo de recuperación de la tendencia y estacionalidad de los datos.

Tomando ventaja de esta particularidad del algoritmo BFAST, en este trabajo se analizan quiebres y recuperación de precios de las acciones de las principales empresas que cotizan en la Bolsa de Valores de Quito para el periodo 2019-2022, y además se prevé analizar la potencial relación de los quiebres detectados con la pandemia del COVID-19.

Capítulo primero

Marco teórico

1. Estado del arte

El precio de cotización de los mercados de valores se caracteriza por un alto dinamismo, en el que intervienen diferentes factores de índole exógenos y endógenos. Desde el punto de vista endógenos, resaltan aspectos relacionados con la volatilidad del mercado y los parámetros propios del mercado. Desde el punto de vista exógeno, resaltan los efectos que pueden tener en los mercados de valores factores macroeconómicos y geopolíticos. En este capítulo, en primer lugar, se presenta una actualización sobre el estado del arte en referencia a los factores que afectan el precio de cotización de acciones en mercados de valores, y los principales enfoques metodológicos empleados para analizar los parámetros dinámicos de series temporales de precios de acciones. En segundo lugar, se presenta el marco teórico diseñado para el desarrollo de esta investigación.

1.1. Impacto de la pandemia del COVID-19 en el precio de las acciones

La pandemia del COVID-19 estuvo asociada con altos niveles de afectación y letalidad a la población global, lo que requirió la implementación de medidas y políticas sin precedentes, en un intento por parte de los gobiernos para desacelerar la expansión del virus. En este contexto, como consecuencia de las restricciones gubernamentales para actividades comerciales y el distanciamiento social voluntario, operando en una economía orientada al servicio, el impacto de la pandemia del COVID-19 es considerado como el que más ha afectado negativamente al mercado de acciones de los Estados Unidos en toda la historia (Baker et al. 2020). En este trabajo, Baker et al. utilizan series históricas de precios del mercado de acciones desde el año 1900 al 2020 (120 años), en conjunto con la volatilidad del mercado desde 1985 al 2020 (35 años), para comprobar, por una parte, que la pandemia COVID-19 ha sido el factor externo que más ha perjudicado al mercado de acciones, y, por otra parte, identificar factores potenciales que permitan explicar el fuerte impacto.

De forma similar, Mendoza-Rivera, Lozano-Díez y Venegas-Martínez (2020, 125) identificaron en un estudio que incluye varios países de Latinoamérica que entre los

diferentes rasgos relacionados con la pandemia del COVID-19, el índice de letalidad impacta negativamente a los índices bursátiles y a las tasas de interés. En este trabajo, los autores destacan que la carencia de modelos predictivos diseñados para tratar con crisis de incertidumbres globales es uno de los factores que han agravado el impacto del COVID-19 en el mercado de acciones. De este modo, los autores destacan que entre los principales factores que sumaron para el impacto generado por el COVID-19, destaca la falta de preparación instalada durante la etapa PRE-COVID.

Para entender a un mayor nivel de detalle, la intensidad de los efectos ocasionados por la pandemia del COVID-19 en el mercado de valores internacional, a continuación se presentan algunos casos de estudio relevantes. De este modo, es importante destacar que hay evidencias de que la pandemia afectó al mercado de valores de forma general. Si bien es cierto que, el nivel de afectación varía de sector en sector, la afectación fue generalizada. La figura 1, muestra uno de los resultados más relevantes reportados por Verma et al. (2021, 9), en el que se representan gráficamente los retornos acumulados para 6 diferentes instrumentos financieros disponibles en los Estados Unidos de América.



Figura 1. Retornos acumulados durante la fase PRE-COVID, y los meses iniciales de la etapa COVID.

Fuente y elaboración: Verma et al. (2021, 9)

En la figura 1, se muestran las series temporales del S&P500 (azul), petróleo (naranja), oro (verde), plata (rojo), gas natural (púrpura), papeles comerciales a 20 años (marrón). También se observan 3 líneas verticales que separan las temporalidades de la serie. La línea verde corresponde al periodo PRE-COVID, la línea roja a la primera caída significativa en febrero de 2020, y la segunda a finales de marzo de 2020. En la figura se puede apreciar los descensos sufridos en los retornos acumulados para cada instrumentos. Estas caídas se hacen notorias en febrero de 2020, y se profundiza en marzo de 2020. Es importante resaltar que, los instrumentos menos volátiles a corto plazo, como lo son el oro y los bonos a 20 años, fueron los menos afectados. También, las caídas relacionadas con S&P500, la plata y el gas natural tuvieron caídas de niveles intermedios, y el que más cayó para marzo de 2020 fue el petróleo, que alcanzó valores de retornos por debajo de 0.

Los resultados reportados por Verma et al., concuerdan de modo sistemático con diferentes estudios similares. Por ejemplo, Boissay y Rungcharoenkitkul (2020, 7) publicaron una revisión preliminar, en el que utilizó el producto interno bruto para generar pronósticos sobre el crecimiento de los Estados Unidos y del Mundo, tomando como referencia datos de la etapa PRE-COVID y del primer trimestre de la fase COVID. Estos estudios fueron realizados por firmas privadas reconocidas, tales como: El banco Alemán, Goldman Sachs, JPMorgan, y Nomura.

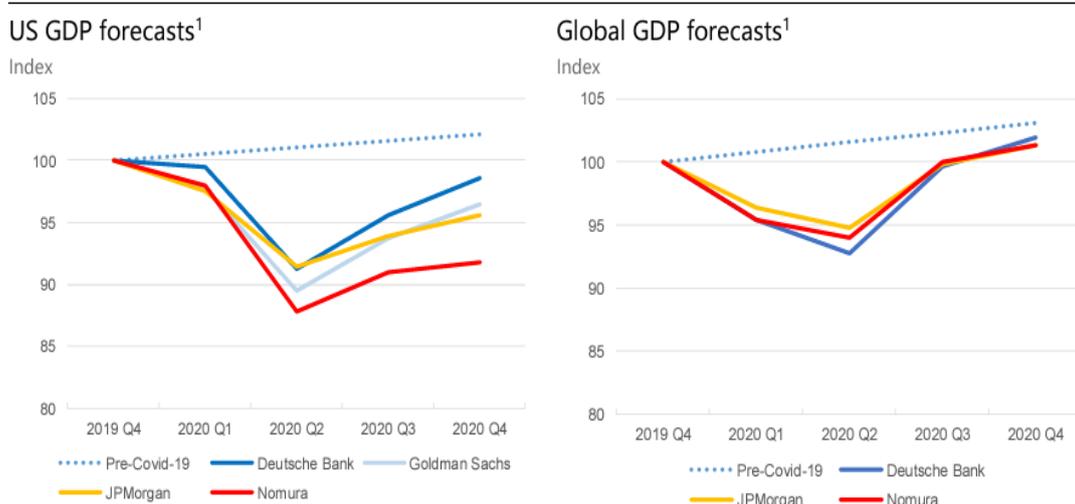


Figura 2. Pronósticos del Producto Interno Bruto, tomando como línea base los niveles PRE-COVID, para los Estados Unidos y el Mercado Global.

Fuente y elaboración: Boissay y Rungcharoenkitkul (2020, 7)

Los pronósticos se muestran en la figura 2, y se aprecia como todos coinciden en una caída significativa en el primer trimestre de 2020, y con profundización en el 2 trimestre de 2020.

Los escenarios pronosticados, en todos los casos presentan una mayor afectación en el crecimiento de los Estados Unidos, en comparación con el medio global (Boissay y Rungcharoenkitkul 2020, 7). Estos resultados, pronosticados, además de ser comprobados en el trabajo de Verma et al. (2020), han sido confirmados también por los resultados reportados por Fernandes (2020, 16), en el que como muestra del nivel del impacto sufrido por la Bolsa de Nueva York, reporta una caída del 30% en el índice S&P500 durante marzo del 2020 (ver figura 3).

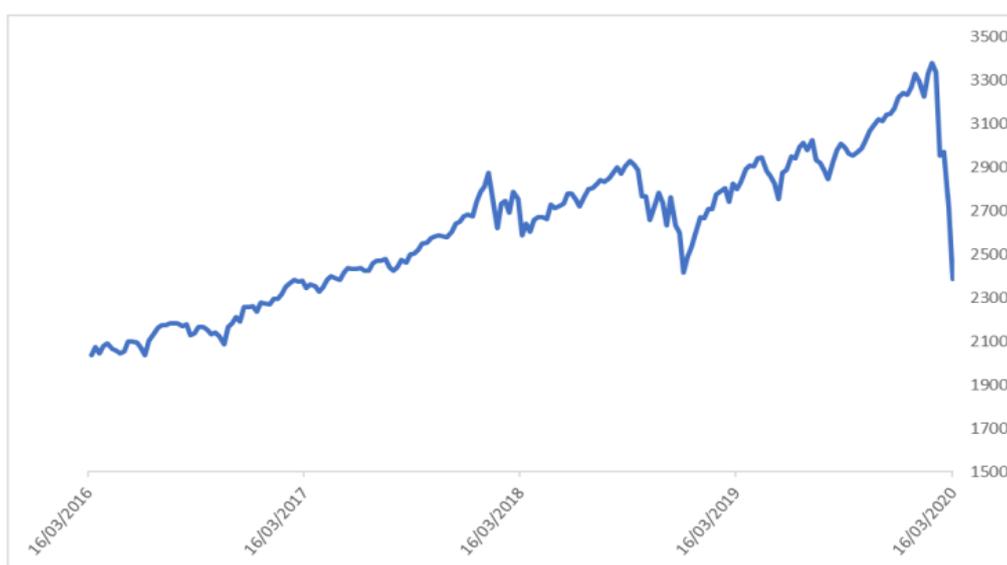


Figura 3. Valor de cotización del S&P500 durante el periodo marzo 2016 a marzo 2020.

Fuente y elaboración: Fernandes (2020, 16)

El S&P500 es un índice que replica el rendimiento de las 500 principales empresas de los Estados Unidos de América, y por ende es una excelente referencia para conocer en promedio el comportamiento de estas empresas en el mercado de valores. Fernandes (2020, 16) reportó de igual modo, resultados correspondientes al desempeño de los principales mercados de valores del mundo. En la figura 4, se muestran ordinalmente el desempeño para 2020 de las bolsas de valores de Japón (Japan), Estados Unidos (US), Portugal, Países Bajos (Netherland), Alemania (Germany), España (Spain) y Reino Unido (UK). Un punto relevante para resaltar de la figura 4, es el hecho de que el país

que menos experimentó caídas es Japón, y sin embargo su caída fue superior al 25% respecto al periodo PRE-COVID.

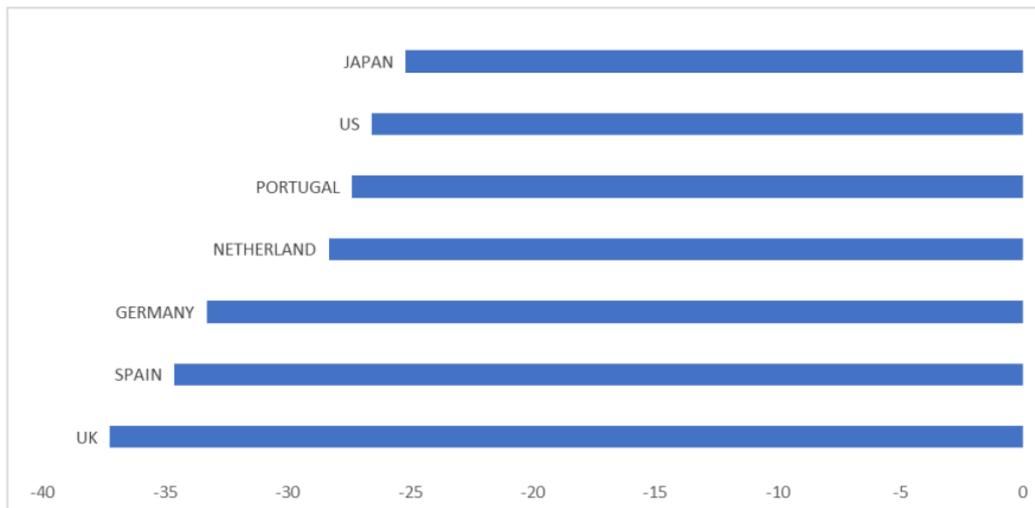


Figura 4. Desempeño de las principales bolsas de valores del mundo durante 2020.
Fuente y elaboración: Fernandes (2020, 16)

Las referencias presentadas en esta sección, permiten comprender el contexto general sobre las características del impacto que generó el COVID-19 en el mercado de valores internacional. Los principales efectos pueden explicarse por una parte en la observación de un quiebre estructural ocurrido en marzo de 2020 en los precios de instrumentos financieros internacionales, y por otra parte en que las caídas del retorno acumulado para 2020, superó en el mejor escenario el 25% respecto a los valores de cotización de la fase PRE-COVID.

En las siguientes secciones de este capítulo, se presentan aspectos relacionados con los efectos que el COVID-19, como eventos de alcance mundial, han ocasionado en mercados financieros, desde una perspectiva general.

1.2. La influencia de eventos mundiales en los precios de acciones

La importancia de comprender la influencia que tienen los eventos mundiales en el precio de las acciones ha sido destacada por múltiples investigaciones en las últimas décadas. Niederhoffer (1971, 193) identificó un patrón de influencia que sugería que la ocurrencia de cambios fuertes en las tendencias de series temporales de precios de acciones están probablemente más vinculados con eventos mundiales que con

comportamientos intrínsecos de los mercados. Sin embargo, Niederhoffer afirma que, en contraste a creencias populares, no existe evidencia de que los cambios ocasionados por eventos mundiales proporcionen información relevante para pronosticar escenarios de precios futuros. Además de la ocurrencia de eventos mundiales, diferentes trabajos han reportado que la influencia del evento sobre el precio de las acciones está altamente vinculado por una parte al nivel de la gravedad del evento, y por otra; a los matices contextuales que tiene la noticia (McQueen y Roley 1993; Niederhoffer 1971; Chan 2001; Savor 2011).

En este contexto, diversas investigaciones han aportado análisis relevantes en referencia a la caracterización de algunos tipos importantes de eventos mundiales, y el impacto que generan en el precio de las acciones, así como en el mercado de valores en general. Por ejemplo, estudios sobre el efecto que los conflictos internacionales tienen sobre el precio de las acciones, han develado que si estos poseen una influencia sistemática de orden geopolítico o financiero, afecta de modo negativo las interacciones de los núcleos de mercados financieros del mundo (Schneider y Troeger 2006, 623).

Los factores políticos, si bien están vinculados a los eventos de conflictos internacionales, merecen un tratamiento especial cuando las agendas están marcadas por motivaciones de orden estratégico y/o ideológicos. Aunque en el caso del mercado de valores de los Estados Unidos no hay evidencia de que el riesgo de mercado esté vinculado a la administración presidencial de turno, el exceso en retorno del mercado de valores ha sido históricamente mayor bajo administraciones de los demócratas que cuando gobiernan los republicanos (Santa-Clara y Valkanov 2003, 1841). Si bien este efecto puede ser explicado desde las diferentes posturas de estas administraciones en referencia a políticas económicas, el hecho es que el comportamiento de las variables macroeconómicas de los Estados Unidos además de tener una fuerte influencia en el precio de las acciones locales, hay evidencias de que también tienen un rol determinante en mercados de valores de países emergentes (Nguyen y Ngo 2014, 149).

1.3. Análisis de efectos de eventos mundiales en el precio de acciones

Históricamente, los mercados de valores mundiales han experimentado comportamientos de inestabilidad que han ocasionado pérdidas irreparables a muchos inversores. En la actualidad, los principales factores relacionados con cambios bruscos en el precio de acciones son: (1) Incertidumbres en políticas económicas, (2) Volatilidad del mercado, y (3) riesgos geopolíticos (Sánchez Gabarre 2020, 265). En dependencia a

condiciones de contexto, estos factores pueden explicar de forma individual o colectiva, anomalías o cambios inesperados en el precio de las acciones de los mercados de valores.

Los eventos mundiales, a los que se hace referencia en este documento, responden a situaciones que pueden tener influencia en los precios de las acciones de mercados de valores por alguno de estos tres factores. Particularmente, estos eventos pueden ocurrir a escala nacional, regional o global, y tienen como consecuencia la alteración imprevista de los precios de las acciones. En el caso de la pandemia del COVID-19, las restricciones de movilidad impuestas por muchos países del mundo, en el contexto de los planes de emergencias para la contención de la pandemia, estuvieron acompañadas de políticas económicas dirigidas a mitigar el efecto contagio en las poblaciones. De este modo, es factible asociar los impactos del COVID-19 en los precios de las acciones, con incertidumbres en políticas económicas. Sin embargo, el cierre de fronteras y las restricciones comerciales y de producción impuestas por diversos gobiernos; generaron efectos en cascada que comprometieron las cadenas de producción y suministros del mundo, lo que le da también un carácter de riesgo geopolítico. A continuación, se presenta una descripción general de las afectaciones que cada uno de estos factores implican para el precio de las acciones.

1.3.1. Incertidumbres en políticas económicas

Es bien conocido que la implementación inadecuada de políticas económicas, tales como inestabilidades en la implementación de políticas monetarias, afectan negativamente los mercados bursátiles (Xin 2014, 19). Bernanke y Kuttner (2003) estimaron que el recorte hipotético e imprevisto en 100 puntos base en el objetivo de la tasa del Fondo de la Reserva Federal (FED) provocaría un aumento del 4% en el mercado de valores de los Estados Unidos. Por otra parte, Honda y Kuroki (2006, 812) condujeron un análisis en el contexto del mercado de valores japonés cuyos resultados sugieren un relación negativa significativa entre cambios súbitos en las tasas de interés y el rendimiento del mercado bursátil.

Si bien estos trabajos confirman la relación negativa presente entre políticas económicas asociadas a las tasas de interés y el mercado bursátil, no siempre se evidencia esta relación inversa característica en el impacto entre estos parámetros. Estudios confirman que los choques o cambios súbitos en política económica, causan efectos asimétricos en el mercado de valores, con efectos mayores en los rendimientos de las acciones en un mercado bajista que en un mercado alcista, estos resultados han sido

observados tanto en el mercado de valores de los Estados Unidos, como en el del Reino Unido (Chen 2007; Henry 2009; Kurov 2010).

Otro factor importante que tienen los choques en políticas monetarias en los mercados bursátiles tiene que ver con la dinámica y presencia de burbujas en el mercado. En este sentido, la respuesta del retorno del mercado en cuanto las sorpresas que generan los choques de políticas monetarias, así como también las condiciones del negocio, deben ser analizadas para entender burbujas en el mercado bursátil. Los autores Fullana, Ruiz y Toscano (2021, 963), usaron un modelo autorregresivo de vector estructural (SVAR, por sus siglas en inglés) con la finalidad de identificar una variable “proxy” de choques de políticas monetarias. Además, en este trabajo los autores implementaron una regresión condicional para evaluar los retornos históricos del mercado en escenarios de choques de política monetaria para extraer las relaciones implícitas entre ambas variables en diferentes escenarios.

Los resultados reportados por los autores resaltan que las políticas monetarias no impactan el retorno del mercado bursátil de forma significativa en escenarios de choques positivos, así como en periodos de expansión. Sin embargo, en condiciones donde los choques de políticas monetarios tienen un carácter restrictivo de baja eficiencia, se identificaron evidencias de coincidencias con la fase del ciclo del negocio en donde las burbujas del mercado tienen su inicio.

Desde este marco de referencia, resulta de interés analizar el rol que pueden tener las políticas de los bancos centrales desde el punto de vista financiero en el rendimiento de mercados bursátiles en economías emergentes. Una referencia interesante para debatir sobre este aspecto es el trabajo presentado por Sharma, Mahendru, y Srivastava (2019, 1). En este trabajo, se realiza un análisis comparativo sobre el rendimiento de mercados financieros durante tres administraciones del Banco de la Reserva de India, considerando las políticas del banco de la reserva con respecto a la estabilidad monetaria, inflación, y metas de crecimiento. Para fines comparativos, los autores han realizado un análisis de retorno y volatilidad en el mercado bursátil y cambiario en comparación con una selección de mercados emergentes (Brasil, Rusia, China, y Sudáfrica) y de mercados desarrollados (USA y UK).

Los autores aplicaron un modelo Exponencial Autorregresivo Generalizado de Heterocedasticidad Condicional (EGARCH) para analizar los rendimientos de cada uno de los mercados financieros que conforman el estudio. Por otra parte, el impacto de las políticas de los bancos centrales en el mercado financiero ha sido analizado usando el

modelo de efecto mixto tanto en el país de estudio como en los países de referencia. Los autores han realizado el estudio sobre el impacto de las políticas monetarias del banco de la reserva de India, considerando las administraciones: periodo 1: 1 de septiembre de 2003 a 5 de septiembre de 2008; periodo 2: 8 de septiembre de 2008 a 4 de septiembre de 2013, y periodo 3: desde el 5 de septiembre de 2013 al 17 de junio de 2016 (Sharma, Mahendru, y Srivastava 2019, 4).

Los resultados obtenidos por los autores destacan que la afectación más directa e inmediata que se deriva de cambios en las políticas de bancos centrales se experimenta en los mercados financieros. El modelo de efecto permitió concluir que el mercado financiero respondió positivamente a los cambios en políticas financieras implementadas en India en el periodo 3, en comparación con los periodos 1 y 2, así como también en comparación con los países considerados como referencia en este estudio. Los factores claves para resaltar en referencia a las políticas adoptadas por el banco de la reserva de India en el periodo 3, se resumen a continuación: (a) mantenerse en los fundamentos básicos, (b) predictibilidad y estabilidad monetaria y (c) presión y gestión de críticas. Como resultado de las políticas financieras adoptadas por el banco de la reserva de India en el periodo 3, en este periodo India exhibe estabilidad monetaria, disminución de la inflación, y mejor tasa de crecimiento durante esta administración.

En el contexto de mercados bursátiles desarrollados, como es el caso de los Estados Unidos, se han realizado análisis para estimar el impacto en el mercado bursátil como consecuencia de los cambios sorpresivos en las tasas de los fondos federales (FFR, por sus siglas en inglés). Particularmente; Kontonikas, MacDonald, y Saggi (2013, 4025), evaluaron el periodo comprendido entre 1989 y 2009, tomando un enfoque particular en la reciente crisis del año 2008. Entre los resultados reportados por los autores resaltan: (i) previo a la crisis, los precios de las acciones aumentaron en respuesta a los cortes inesperados de los FFR, (ii) cuando las acciones exhiben aumentos prolongados que coinciden con recesiones se hace más notable la influencia del estado en el mercado financiero. Sin embargo, durante la crisis financiera se observó un cambio estructural en estos comportamientos; que modificó tanto la respuesta del mercado a los FFR, como a la dependencia del estado. Específicamente, durante el periodo de la crisis los participantes del mercado bursátil no reaccionaron de forma positiva a los cortes inesperados en los FFR.

1.3.2. Volatilidad del mercado

En esta sección, se realiza una revisión de la literatura sobre la relación que existe entre la volatilidad de mercados bursátiles con actividades macroeconómicas. Engle, Ghysels, y Sohn (2013, 776), propusieron un nuevo modelo de componentes que permite distinguir desde movimientos de corto plazo a largo plazo. El modelo desarrollado incluye un componente a largo plazo que incluye la inflación y el crecimiento de producción industrial, que son términos reconocidos por su potencial para realizar predicción a escalas horizontales, en comparación con enfoques tradicionales de análisis de volatilidad a partir de series temporales. Los autores reportan que utilizar variables de entrada fundamentales económicos como la inflación, proporciona información relevante para predecir a largo plazo en escala horizontal, mientras que los fundamentales macroeconómicos juegan un rol importante a corto plazo.

Conrad y Loch (2012, 1), estudiaron la relación a largo plazo entre los riesgos del mercado bursátil de Estados Unidos y el ambiente macroeconómico. Para esto, los autores implementaron un modelo GARCH-MIDAS de dos componentes. Los resultados obtenidos muestran una evidencia significativa en favor de un comportamiento contra cíclico en la volatilidad del mercado a largo plazo. El conjunto de variables predictoras utilizadas en el modelo incluye el diferencial de plazo, construcción de viviendas iniciadas, los beneficios empresariales y la tasa de desempleo, considerando que tienen la mayor capacidad de predicción de la volatilidad del mercado de valores. El diferencial de plazo y la construcción de viviendas son variables que orientan la predicción de la volatilidad de mercados; el beneficio empresarial y la tasa de desempleo proporcionan información importante y permiten visualizar escenarios de desarrollo futuro. Estos resultados permiten deducir que el uso de macro-variables contribuye positivamente en procesos de predicción de volatilidad a largo plazo.

En este contexto, se ha determinado que además de considerar la ventana de tiempo de predicción de la volatilidad de mercados, utilizando escalas a largo o corto plazo, la definición de un valor central de frecuencia para los datos es de mucha importancia. Dominicy y Vander (2015, 1) analizaron las ventajas asociadas con la definición de una frecuencia particular para los datos de estudio, diferenciando entre datos de baja frecuencia y de alta frecuencia. En particular, los autores implementan un modelo LGARCH con la finalidad de estudiar el uso combinado de datos de alta frecuencia y variables económicas para modelar y predecir retornos y volatilidades en mercados financieros. De esta forma, utilizando una serie temporal de alta frecuencia con una

extensión superior a 10 años para transacciones de 55 participantes que cotizan en el mercado bursátil de los Estados Unidos, los autores dedujeron que la combinación de indicadores exógenos de baja frecuencia con datos financieros de alta frecuencia permite mejorar la habilidad para predecir retornos y volatilidades del sistema.

1.3.3. Riesgos geopolíticos

Los efectos que pueden experimentar los precios de acciones en los mercados de valores por consecuencia de agendas políticas estratégicas multilaterales, o con alcance regional o global, son conocidos como riesgos geopolíticos asociados al sector financiero. Los riesgos geopolíticos (GPR, por sus siglas en inglés) pueden ser de alcance doméstico (o nacional), o de alcance global. En países de economías emergentes, como el caso ecuatoriano, no existen evidencias significativas de que los GPR de escala nacional ejerzan una influencia directa sobre los precios de las acciones del mercado de valores nacional (Bouras et al. 2019, 1841). Bouras et al (2019) realizaron un análisis comparativo sobre la afectación debida tanto a GPR de origen nacional y globales en 18 mercados de valores asociados a países emergentes durante el periodo comprendido entre noviembre de 1981 a junio de 2017.

El enfoque de análisis utilizado por Bouras et al. (2019), incluyó la implementación de un modelo Autorregresivo Generalizado de Heteroscedasticidad Condicional (GARCH, por sus siglas en inglés). En lugar de utilizar un modelo GARHC basado en análisis tradicional de series temporales, propusieron un enfoque que ofrece una ganancia de eficiencia sustancial en la estimación de los procesos condicionales de varianza y covarianza a partir de la contabilidad de interdependencia y heterogeneidad entre las diferentes economías. Los resultados obtenidos por estos autores confirman la hipótesis de que los GPR a escala nacional tienen un efecto no significativo en los retornos o volatilidades de mercados nacionales emergentes; mientras que, los GPR de escala global muestran una correlación significativa con los retornos y volatilidades de los mercados bursátiles emergentes.

La identificación de esta relación entre los GPR y el retorno y volatilidad del precio de acciones en mercados de valores han motivado el desarrollo de diversas investigaciones orientadas a explorar la potencialidad de predecir el comportamiento y/o tendencia del precio de acciones ante la presencia de GPR particulares (Bouri et al. 2019, 367). Por ejemplo, Apergis et al. (2017, 1) aplicaron una prueba de causalidad no paramétrica de orden k-ésimo a una frecuencia mensual para el periodo comprendido

entre enero de 1985 y junio de 2016, con la finalidad de analizar si los GPR permiten predecir tendencias de retornos y volatilidades en los precios de las acciones de 24 firmas globales en el sector de la defensa.

Los enfoques no paramétricos permiten controlar la falta de especificaciones en marcos de causalidades lineales, y, por ende, la escasa evidencia se asocia con baja confiabilidad sobre las pruebas estándares de Granger. En este contexto, Apergis et al. (2017, 1) resaltan que la implementación de las pruebas no paramétricas no arrojan evidencias sobre la predictibilidad de los retornos del precio de las acciones en las 24 empresas de la defensa, como consecuencia del impacto generado por mediciones de GPR. Sin embargo, índices de GPR predijeron la volatilidad medida en el 50% de estas compañías. Estos resultados reflejan que, si bien los eventos geopolíticos globales para un periodo de tiempo no permiten predecir el retorno, si generan información relevante para definir perfiles de riesgos futuros en empresas del sector de la defensa.

Un factor importante, en el estudio de GPR consiste en el índice específico utilizado para la medición del impacto en los precios de acciones de mercados de valores. En este sentido, los índices de medición del impacto de GPR basados en noticias, están relacionados con la volatilidad de mercados de valores. Gkillas, Gupta, y Wohar (2018, 247) realizaron un estudio para determinar el rol de los índices basados en noticias (NBI's, por sus siglas en inglés) para la predicción de saltos en la volatilidad del precio de cotización del índice de Promedio Industrial Down Jones (DJIA, por sus siglas en inglés) para el periodo definido entre enero de 1989 y diciembre de 2017 con frecuencia diaria. Si bien en este estudio las pruebas de estándares de causalidad de Granger fallaron en la búsqueda de causalidad entre los GPR y los saltos de volatilidad, en este estudio al igual que el reportado por Apergis et al. (2017, 1), el uso de modelos no paramétricos de causalidad, permitieron detectar relaciones fuertes no lineales de quiebres entre los GPR y los saltos de volatilidad del DJIA.

Si bien, los factores asociados a los cambios que pueden experimentar las acciones de empresas que cotizan en mercados de valores, no están limitados de forma exclusiva a los tres tratados en esta sección; estos proporcionan un marco conceptual general que permiten explicar las principales fuentes de cambios que pudieran ser detectados en este trabajo mediante la implementación del algoritmo BFAST. Un caso no discutido hasta el momento es el impacto ocasionado por la pandemia del COVID-19 en el mercado de valores, tanto a escala global como a escala nacional. Por este motivo, en este contexto se proporciona un marco de referencia sobre trabajos recientes que han generado aportes

en comprender y dimensionar los efectos ocasionados por el COVID-19 en los mercados financieros en general.

2. Fundamentos teóricos

La relevancia empírica del análisis de Quiebres Estructurales (QE) para comprender las volatilidades de precios de acciones en mercados de valores ha sido comprobada en investigaciones previas (D. E. Rapach y Strauss 2008; D. Rapach, Strauss, y Wohar 2008; Chatzikonstanti 2017). Una de las pruebas de cambios estructurales ampliamente más utilizadas son las series cuadradas de Suma Cumulativa (CUSUM, por sus siglas en inglés) (Xu 2013). CUSUM es especialmente útil cuando no se dispone de información o conocimiento a priori sobre el tipo de cambio estructural potencial.

Hasta el presente se han utilizado diversos enfoques basados en CUSUM para el diseño e implementación de herramientas de detección de quiebres estructurales en series temporales de datos financieros, partiendo de la prueba de QE propuesta por Brown, Durbin, y Evans (1975). Dentro de estos enfoques, dos marcos principales resaltan en la literatura: (i) enfoques basados en el estadístico F (Andrews 1993; Andrews y Ploberger 1994), que son designados para una alternativa específica y (ii) enfoques basados en pruebas de fluctuación generalizada (Kuan y Hornik 1995), en los que no se asume un patrón particular de desviación respecto a los QE. Para mayor amplitud sobre este tópico, Sánchez (2008) aportó un trabajo detallado sobre el estado del arte para la detección de Quiebre estructurales, en donde además de CUSUM, se mencionan otros enfoques y principios conceptuales.

En el área de la econometría han sido desarrollados diversos enfoques metodológicos para la detección de QE en series temporales a partir de pruebas secuenciales (Bai y Perron 2003; Zeileis et al. 2003). Estos métodos se basan en el ajuste de un modelo lineal en las secciones de una serie temporal, en los que los QE ocurren. Tomando ventaja de este procedimiento, Haywood y Randal (2008) propusieron un modelo iterativo para agregar y estimar componentes de tendencias y estacionalidades en el análisis de QE en series temporales. En la siguiente ecuación, se muestra el modelo presentado:

$$Y_t = T_t + S_t + I_t$$

donde $t = 1, \dots, T$, Y_t son datos observados, T_t es un componente de tendencia no observado explícitamente en los datos, S_t es un componente de estacionalidad no observado explícitamente en los datos, y I_t es un componente irregular no observado

explícitamente en los datos. Considerando que el modelo planteado es un modelo aditivo, en él se establece que el dato observado es el resultado de la suma de componentes asociados a tendencias, estacionalidades e irregularidades; los autores aclaran que aun cuando no todas las series temporales siguen una descomposición aditiva, es siempre posible aplicar una transformación de estabilización factible. En este contexto, en el modelo propuesto la evolución de los componentes de tendencia y estacionalidades son modelados como QE que ocurren en puntos de quiebre identificados endógenamente. A corto término, pueden ocurrir cambios aleatorios que son modelados a partir del componente irregular I_t . Los autores asumen que entre dos puntos de quiebre t_{j-1}^* y t_j^* ($j=1, \dots, m+1$), la tendencia es lineal, y tiene la forma:

$$T_t = \alpha_j + \beta_j t$$

para $t = t_{j-1}^* + 1, \dots, t_j^*$ y $j = 1, \dots, m$. Donde, α_j representa los puntos de corte para el modelo lineal inter-quiebres, y β_j con las pendientes de cambios asociadas con los quiebres. De forma similar, entre cada par de puntos de quiebre, la componente de estacionalidad es dada como:

$$S_t = \sum_{i=1}^{s-1} \delta_{i,j} D_{i,t}$$

para $t = t_{j-1}^* + 1, \dots, t_j^*$, donde $D_{i,t}$ son amplitudes de estacionalidades iguales a uno si el tiempo t de la estacionalidad es i , y cero en los demás casos. A diferencia de los trabajos presentados por Bai y Perron (2003) y Zeileis et al. (2003), el enfoque planteado en este trabajo permite identificar y explicar datos considerando componentes de tendencias y estacionalidades.

2.1. El algoritmo BFAST

La detección de quiebres estructurales, en ocasiones denominada detección de punto de cambio, es concebida conceptualmente desde dos perspectivas: i) pruebas históricas, en donde se utilizan datos históricos para detectar quiebres estructurales en series temporales para líneas de tiempo del pasado, y ii) de modo secuencial, en el que se define el fin del periodo histórico, y a partir de este cada dato observado se considera nuevo, y debe pasar por la prueba de quiebre estructural.

En la literatura, es posible identificar diversas opciones metodológicas para realizar pruebas de quiebres estructurales en series temporales. Entre estas opciones

resaltan el Test de Chow (Alarcón y Maldonado 2022, 13) CUSUM (Sánchez 2008, 14), ARMA-GARCH (Chang y Li 2022, 15107), MOSUM (Chia-Shang, Hornik, y Chung-Ming 1995, 1), etc. BFAST, es un algoritmo que ha sido desarrollado, a partir de una mejora conceptual de la prueba MOSUM.

BFAST integra la descomposición iterativa de series temporales de los componentes de tendencia, estacionalidad y ruido, con métodos de detección de cambios, sin la necesidad de seleccionar periodos de referencia, establecer umbrales de cambios, o definir una trayectoria de cambio. Debido a esto, BFAST posee una potencialidad relevante para la detección de cambios abruptos múltiples en la estacionalidad y componentes de tendencias en las series temporales. Además, BFAST permite la caracterización de cambios graduales y abruptos a partir de la derivación de tiempo, magnitud, y cambios de dirección en el componente de tendencia de la serie temporal.

La figura 5, muestra los componentes que el algoritmo BFAST puede identificar en una serie de temporal de datos: (i) los datos son separados en datos históricos y datos de observación a partir de la definición de periodos de estudios por parte del usuario, (ii) el algoritmo permite caracterizar la estacionalidad de la serie temporal (si existe), (iii) define la tendencia a partir del periodo histórico de los datos, y el periodo de observación es analizado respecto a esta tendencia para detectar quiebres y anomalías en el periodo de observación, (iv) las anomalías son comparadas con los valores estadísticos críticos de la serie temporal para reducir errores en la generación de alertas.

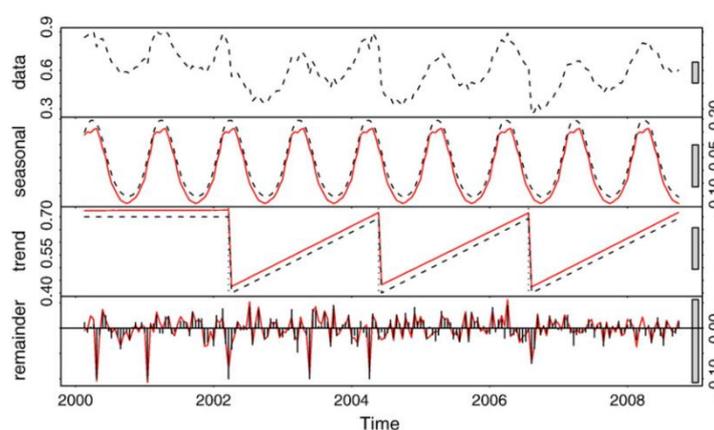


Figura 5. Componentes de análisis de series temporales identificados mediante el algoritmo BFAST

Fuente y elaboración: Verbesselt et. al. (2010, 23)

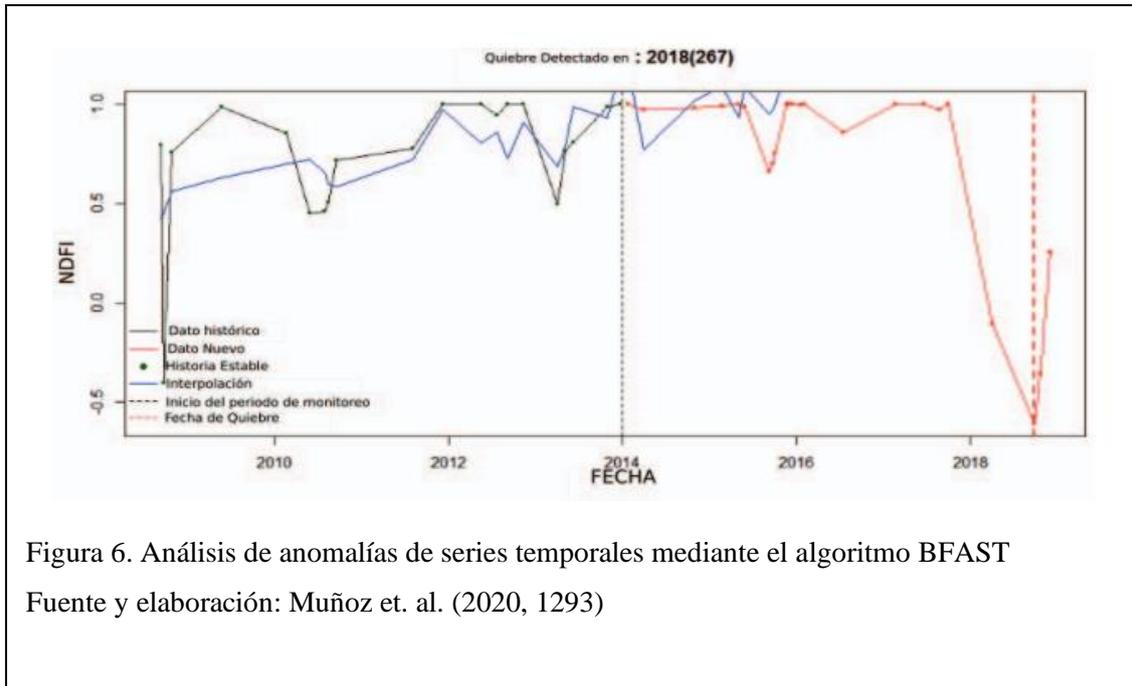


Figura 6. Análisis de anomalías de series temporales mediante el algoritmo BFAST

Fuente y elaboración: Muñoz et. al. (2020, 1293)

En el caso de esta propuesta de investigación, el análisis de anomalías de las series históricas de precios de acciones se fue llevado a cabo mediante el algoritmo BFAST. En la figura 6, se muestran los componentes conceptuales de BFAST. En este trabajo, se plantea el análisis del índice espectral NDFI para los años 2008 a 2019, y se aprecia que se ha definido como periodo histórico 2008-2014 y como observación el periodo 2015-2019 (Muñoz, Zozaya, y Lindquist 2020).

La función de color negro representa los datos históricos, la azul la tendencia, la roja los datos observados. Se aprecia que próximo a 2016 hay una caída importante en el índice, sin embargo, el algoritmo no lo detecta como quiebre (o anomalía) porque este evento corresponde a una estacionalidad con periodos de 3 años que se presentó también en 2010 y en 2013. Sin embargo, en 2019 la recta roja discontinua vertical si corresponde a un quiebre en la serie temporal, y el algoritmo lo detecta de forma automática. Este enfoque metodológico será utilizado en esta investigación para detectar y caracterizar anomalías en las series históricas de precios de las acciones.

Capítulo segundo

Marco empírico

1. Fuentes de información

Para el estudio del comportamiento de precios en las principales empresas que cotizan en la Bolsa de Valores de Quito (BVQ) y su relación con la pandemia COVID-19, se realizó la solicitud de series históricas de los precios diarios de acciones en la BVQ. Los datos serán solicitados desde 2013 para poder caracterizar de forma robusta la serie temporal, y poder contar con suficientes datos para la definición del periodo de datos históricos en el algoritmo BFAST. De esta forma, el periodo de análisis comprende desde enero del 2013 a diciembre de 2022. Es importante destacar que, las empresas que iniciaron su periodo de cotización posterior al año 2013, el periodo histórico inicia desde el primer registro de cotización disponible.

Como datos secundarios, se utilizaron los reportes ECUINDEX para realizar la identificación de las principales empresas que cotizan en la BVQ. Para esto se considerarán las empresas más frecuentes en el ECUINDEX durante el periodo de estudio. Es importante destacar, que los datos provenientes de la Bolsa de Valores de Quito no son abiertos al público. Para acceder a estos datos, los interesados deben realizar un pago, y posterior a este pago, los archivos son enviados por email en formato xlsx. Sin embargo, en el sitio web de la Bolsa de Valores de Quito, se puede acceder de forma gratuita a los dos últimos años de cotización diaria.

2. Enfoque de procesamiento

Las series históricas de los precios diarios de las acciones serán transformados a medias mensuales para la realización de este estudio. Entre las principales ventajas de utilizar datos mensuales, en lugar de diarios, resalta el hecho de que las variaciones atípicas en la media son mayores para datos diarios que para datos mensuales. También es importante mencionar que el dato mensual permite realizar un análisis más adecuado considerando que el periodo de estudio comprende tres años de datos.

Los datos serán procesados mediante el algoritmo BFAST, y en las series donde se detecten anomalías, se realizará una evaluación posterior para identificar si existe interconexión entre dicha anomalía y la presencia de la pandemia del COVID-19.

Desde el punto de vista del análisis de datos, algunos autores estudian el impacto del COVID-19 en el mercado de valores a partir del análisis de anomalías en las series históricas de los precios de cotización de las acciones de empresas con variables económicas (Ruiz et al. 2020; Ayittey et al. 2020). Para esto, generalmente se utiliza como enfoque metodológicos modelos basados en aproximaciones econométricas, que permiten proporcionar soluciones empíricas al proceso de estimación del impacto (Yousfi et al. 2021).

3. Metodología de la investigación

La naturaleza cuantitativa de este trabajo de investigación, demanda la necesidad de realizar un análisis exploratorio, descriptivo y relacional de los datos recolectados, con la finalidad de alcanzar resultados concluyentes sobre dos temas particulares: i) por una parte, analizar los quiebres estructurales en series temporales de una muestra representativa de empresas que cotizan en la Bolsa de Valores de Quito mediante el algoritmo BFAST, y ii) por otra parte, determinar si existe relación entre quiebres detectados para el periodo 2019-2022 de las series temporales con la pandemia COVID-19.

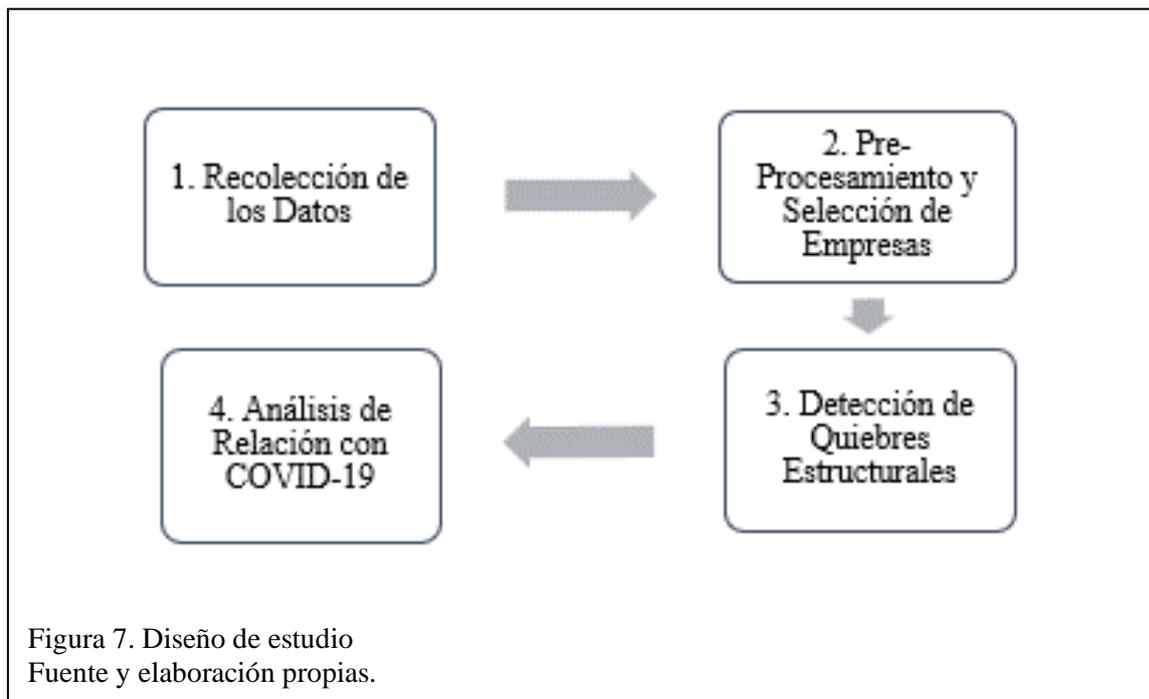
Esta propuesta de investigación incluye como novedades los siguientes puntos:

1. Es el primer estudio en el que se utiliza el algoritmo BFAST para detección de quiebres estructurales de series temporales de mercados financieros
2. Es el primer estudio en el que se evalúan los potenciales efectos del COVID-19 en la Bolsa de Valores de Quito a partir de la detección de quiebres estructurales

En los siguientes apartados de esta sección, se describe el diseño metodológico diseñado en el contexto de esta investigación, para el abordaje de los objetivos de este estudio.

3.1 Diseño del Estudio

En el diseño metodológico de esta investigación, se ha previsto la consolidación de un flujo de trabajo que permita cumplir tantos los objetivos específicos, como el objetivo general planteado. Es en este contexto, en el que en la figura 7., se ilustra el diagrama de flujo derivado del diseño de estudio para esta investigación.



La primera etapa del diseño de estudio mostrado en la Figura 7., consiste en la recolección de los datos. En esta primera etapa, se realizó la solicitud de datos a la Bolsa de Valores de Quito.

En la segunda etapa, se realiza el preprocesamiento de los datos recopilados y la selección de 10 empresas para los casos de estudio. Este proceso consiste en la lectura de los datos anualizados que proporciona la Bolsa de Valores de Quito, descartar las empresas que cotizan en la Bolsa de Valores de Guayaquil. Posteriormente, se deben calcular los precios de cotización medio mensuales de cada empresa, y fusionar los archivos anuales desde el año 2013 hasta diciembre de 2022, para poder conformar las series temporales. Cubiertos estos pasos, se deben seleccionar a las 10 empresas con las series temporales más completas. Luego, se debe interpolar las series temporales de cada una de las empresas seleccionadas y fusionar los archivos de las 10 empresas en uno solo para facilitar la etapa de detección de quiebres estructurales.

Es pertinente resaltar, que si bien es deseable poder analizar un mayor número de empresas para tener un contexto más general sobre los efectos del COVID-19 en la Bolsa de Valores de Quito; un factor que tuvo que ser considerado para poder seleccionar las empresas fue el número de cotizaciones mensuales hasta diciembre de 2022. En este contexto, se descartaron las empresas que tuvieran menos de 50 cotizaciones durante el periodo de estudio. Esto con la finalidad de que el proceso de interpolación no tuviera un efecto distorsionador sobre los datos analizados.

La tercera etapa del flujo de trabajo consiste en la detección de quiebres estructurales para el periodo enero 2019 a diciembre de 2022 de cada una de las series temporales correspondientes a las 10 empresas seleccionadas. Esta etapa de trabajo es de mucha relevancia para esta investigación; por una parte, se va a implementar el algoritmo BFAST por primera vez para el análisis de series temporales de un mercado de valores, y, por otra parte, los quiebres serán utilizados para identificar la posibilidad de afectación en la Bolsa de Valores de Quito a consecuencia de la pandemia del COVID-19.

Este contexto, naturalmente demanda la necesidad diseñar un esquema comparativo que permita evaluar las potencialidades del algoritmo BFAST para la detección de quiebres estructurales en series temporales de tipo financiero. Para esto, se seleccionó un algoritmo de referencia con documentación suficiente y eficiencia comprobada en la detección de quiebres estructurales en series temporales de mercados de valores. La revisión de la literatura permitió identificar a los algoritmos de suma acumulada (CUSUM) y suma de medias móviles (MOSUM) como dos de los más utilizados para la detección de quiebres de series temporales en mercados de valores.

Este hallazgo, orientó la búsqueda hasta llegar a la librería de R *Strucchange*. Esta librería cuenta con la implementación de CUSUM y MOSUM, y además puede ser corrida desde R, que es precisamente donde está implementado BFAST. De este modo, la detección de quiebres estructurales ha sido realizada tanto con el algoritmo BFAST, como por *Strucchange*. En ese sentido, se tiene el marco comparativo que permita concluir sobre las potencialidades de BFAST.

La etapa cuatro del diseño del estudio, consiste en realizar un análisis que permita identificar indicios sobre la afectación de la pandemia del COVID-19 a las 10 empresas seleccionadas para este estudio. Para facilitar este análisis, el intervalo temporal de este estudio ha sido dividido en tres fases: a) la fase 1 denominada PRE-COVID inicia en enero de 2019 y finaliza en diciembre de 2019, b) la fase COVID que inicia en enero de 2020 y finaliza en diciembre 2020, y c) la fase POST-COVID que inicia en enero de 2021

y finaliza en diciembre de 2022. La segmentación temporal del análisis facilita la evaluación de las anomalías presentes en las series temporales, y además se puede evidenciar en qué fase temporal ocurren.

A fin de estructurar de mejor forma el análisis, se realizó una agrupación de las empresas por sectores económicos de acuerdo con su giro de negocio. De este modo, se obtuvo 2 sectores: Sector Financiero y Sector Productivo y Comercial. La segmentación de las empresas entre estos dos sectores permite realizar un análisis general sobre los quiebres obtenidos, y de igual modo facilita la identificación de aspectos comunes que pudieron tener lugar en empresas de mismo sector como consecuencia de la pandemia de COVID-19.

3.2. Definición del periodo temporal del estudio

La enfermedad del Coronavirus (COVID-19) fue oficialmente reconocida por la Organización Mundial de la Salud (OMS) el 31 de diciembre de 2019, fecha en la que según esta organización fue notificada por primera vez la presencia del brote en la ciudad de Wuhan (China). De este modo, de acuerdo con la OMS, los efectos del COVID-19 inician en el contexto internacional el 01 de enero de 2020 (OMS 2020a, párr. 1). Desde este momento, el brote de COVID-19 comienza a esparcirse a nivel mundial, hasta que el 11 de marzo de 2020, el director general de la OMS anuncia que el COVID-19 debía ser catalogada como pandemia (OMS 2020b, párr. 1). En el caso particular del Ecuador, el caso cero de COVID-19 había sido anunciado el 29 de febrero de 2020 por la entonces ministra de Salud Pública, Catalina Andramuño (S. G. de C. de la P. EC 2020, párr. 1).

El alto índice de letalidad del COVID-19, aunada con el desconocimiento sobre el virus y la falta de preparación llevaron a la necesidad de imponer medidas restrictivas de movilidad y libre tránsito que incluyeron el cese del aparato productivo y comercial a nivel nacional e internacional, a excepción de sectores prioritarios relacionados con la medicina y alimentación, entre otros pocos (M. de P. C. E. I. y P. EC 2020, párr. 2). En este contexto, el 2020 estuvo caracterizado por inestabilidad en el primer trimestre relacionadas con la proliferación y expansión del COVID-19, el segundo y tercer trimestres caracterizado por toques de queda y paradas en los sistemas productivos y comerciales a escala nacional e internacional, y el cuarto trimestre por el inicio del proceso de recuperación de la normalidad.

Finalizado el 2020, comienza el proceso de recuperación y retorno de la normalidad de las actividades productivas y comerciales mundiales. Sin embargo, es

importante mencionar que durante 2021, muchos países continuaron implementando medidas cautelares para evitar nuevos brotes del virus. De este modo, 2021 y 2022 están caracterizados por el inicio de recuperación y vuelta a la normalidad.

Considerando estos antecedentes, y reconociendo que el mercado de valores nacional guarda una relación importante con mercados de valores internacionales, entre otras cosas, como consecuencia de la dolarización y de la globalización económica; en este trabajo de investigación se ha definido el periodo desde el 01 de enero al 31 de diciembre de 2019 como periodo PRE-COVID, desde el 01 de enero de 2020 al 31 de diciembre de 2020 como periodo COVID, y desde el 01 de enero de 2021 al 31 de diciembre de 2022 como periodo POST-COVID.

El periodo PRE-COVID es utilizado en este estudio como línea base para definir el comportamiento y tendencia del precio de cotización de acciones de la Bolsa de Valores de Quito en ausencia del coronavirus. El periodo COVID se utiliza para estudiar el efecto de la pandemia en los precios de cotización de las empresas incluidas en el estudio. Finalmente, el periodo POST-COVID se utiliza para evaluar y caracterizar la existencia de recuperación en los precios de cotización de las acciones, en los casos que aplique.

3.3. Modelo Empírico

3.3.1. Tendencias actuales en el análisis de precio de acciones

Las series temporales de datos hacen referencia a una secuencia o conjunto de puntos de datos que una variable toma a intervalos de tiempos iguales. De acuerdo con Idrees, Alam, y Agarwal (2019, 17287), el mercado de valores es considerado como uno de los sistemas financieros más complejos, que consiste de varios componentes o acciones, cuyo precio fluctúa considerablemente en el tiempo. La predicción de estados del mercado de valores incluye, por tanto, descubrir las tendencias de los mercados a tiempo futuro. Existen numerosos retos asociados a la intención de predecir estados de mercados de valores, y estos retos están catalizados por una alta sensibilidad que se asocian a las acciones que cotizan en los mercados de valores a factores que puedan inducir cambios rápidos e inesperados.

Sin embargo, a pesar de las numerosas dificultades asociadas, la predicción de mercados de valores es considerada un área de investigación activa, debido en gran parte

que el objetivo final de la predicción de mercados es el de generar beneficios financieros a partir de la generación de insumos para una toma de decisión precisa y acertada en el contexto de inversiones financieras. Los autores, propusieron un modelo estadístico con la finalidad de estimar eficientemente predicciones de estados a partir de series temporales de un conjunto de acciones del mercado de valores de India.

El modelo estadístico construido por los autores se basa en modelos estadísticos clásicos implementados en el área de econometría para llevar a cabo procesos de predicción y construcción de escenarios económicos. Entre los modelos evaluados por los autores resaltan: el Modelo Autorregresivo (AR), el modelo de Medias Móviles (MA), el modelo combinado de medias móviles y autorregresivo (ARMA), y el modelo autorregresivo integrado de medias móviles (ARIMA). Cada uno de estos métodos proporcionan técnicas específicas orientadas a explotar información contenida en conjuntos de datos de series temporales.

Estos modelos estadísticos para el análisis de series temporales se encuentran de forma recurrente en la literatura especializada como herramientas utilizadas para la predicción de estados de acciones en mercados de valores. Por ejemplo, Adebisi, Adewumi, y Ayo (2016, 105) construyeron un modelo ARIMA para la predicción de precios de acciones en el mercado de valores de los Estados Unidos, así como también del mercado de valores de Nigeria. Los autores colectaron datos del mercado publicados por la Bolsa bursátil de New York (NYSE, por sus siglas en inglés) y por la Bolsa de Valores de Nigeria (NSE) para construir las series temporales de entrada para el modelo predictivo.

Los resultados reportados por los autores afirman que el modelo ARIMA tiene un fuerte potencial para predicción a corto plazo, y que puede competir favorablemente con las técnicas modernas para la predicción de precios del mercado de valores. Resultados similares han sido reportadas por diversos autores. A modo de referencia, es pertinente mencionar que Ponnampalath et al (2016, 1) realizaron un análisis comparativo sobre técnicas ampliamente usadas para la predicción de mercados de valores.

Actualmente, los enfoques metodológicos para la construcción de modelos predictivos para precios de acciones de mercados de valores incluyen técnicas modernas basadas en inteligencia artificial. Un caso práctico de esta tendencia es el trabajo realizado por Yücel (2020, 709), en el que propone una evaluación sistemática y conceptual sobre el efecto de utilizar técnicas de Aprendizaje Profundo (DL) para la construcción de modelos predictivos. Conceptualmente, el autor establece como primicia que existe una

relación entre el comportamiento a futuro del mercado de valores con los datos históricos, y que el proceso de predicción consiste en determinar los escenarios futuros más probables, utilizando como insumo los datos históricos, e incorporando variables predictoras con alta correlación.

DL es una de las técnicas más recientes desarrolladas en el campo de la inteligencia artificial (IA), orientadas a utilizar conjuntos de datos para entrenar algoritmos capaces de predecir estados en situaciones acotadas. Por ende, la potencialidad de predicción de algoritmos construidos con técnicas de inteligencia artificial está determinada por la generalidad intrínseca de los datos históricos, en términos de que sean suficientemente extensos y completos, para permitir al algoritmo entrenado la consideración de la mayor cantidad de escenarios posibles en el contexto de un evento de predicción. Si bien, existen un gran número de enfoques metodológicos para la construcción de modelos predictivos, en este trabajo se han mencionados algunos relevantes para contextualizar al lector en el marco de esta investigación.

3.3.2. Análisis de series temporales mediante el algoritmo BFAST.

El algoritmo para Quiebres, Estacionalidades y Tendencias Aditivas (BFAST, por sus siglas en inglés), es un algoritmo conocido en el área de geomática aplicada, debido a sus múltiples aplicaciones orientadas a analizar series temporales de índices basado en la construcción de imágenes satelitales (Schultz et al. 2016, 3667). El algoritmo BFAST se ha sido diseñado a partir de la incorporación de tres componentes: (i) componente para la detección de puntos de quiebre, (ii) componente para el análisis de estacionalidades, y (iii) componente para el análisis de tendencias; el resultado de combinar estos tres componentes en un algoritmo de análisis de series temporales, consiste en una mejora de la exactitud del modelo para detectar cambios en comparación con detectar únicamente puntos de quiebre (Grogan et al. 2016, 1).

Al momento de escritura de este documento, las aplicaciones publicadas con el uso de BFAST comprenden áreas como: (i) monitoreo forestal (Reiche et al., 2015; Gao et al., 2021), (ii) cambio de cobertura y uso de suelos (Zhu y Woodcock 2014), y (iii) detección de cambios fenológicos en vegetación (Verbesselt, Hyndman, Zeileis, et al. 2010). Sin embargo, no se ha encontrado en la literatura aplicaciones de este algoritmo en el campo de análisis de series temporales de datos de mercados financieros. En este contexto, en este trabajo se evaluará la potencialidad y generalidad del algoritmo BFAST para el análisis de series temporales de precios de acciones.

Para realizar la detección de Quiebres Estructurales, en este trabajo se ha propuesto utilizar el algoritmo BFAST, con la finalidad de evaluar su potencialidad para aplicaciones en el sector financiero. Por consiguiente, la evaluación de los resultados generados mediante BFAST, es realizada mediante la comparación con el algoritmo CUSUM, el cuál ha sido implementado en este trabajo mediante la librería Strucchange. A continuación se presentan los rasgos conceptuales principales de ambos algoritmos.

En referencia a BFAST es importante mencionar que, si bien BFAST está basado en el modelo conceptual propuesto por Haywood y Randal (2008), la propuesta de BFAST difiere de este en:

1. Usa el proceso de descomposición tendencia-estacionalidad (STL) para estimar el componente inicial de la estacionalidad \widehat{S}_t
2. Usa un procedimiento robusto para la estimación de los coeficientes α_j , β_j , y $\gamma_{i,j}$
3. Implementa una prueba de QE.
4. Obliga a los coeficientes estacionales a siempre sumar cero, en lugar de ajustarlos posteriormente en el proceso de iteración.

Como resultado de este procedimiento, BFAST proporciona una estimación de magnitud de cambio entre puntos de quiebre consecutivos mediante la siguiente expresión:

$$\text{Magnitud} = (\alpha_{j-1} - \alpha_j) + (\beta_{j-1} - \beta_j)t$$

En esta expresión, la magnitud de cambio es estimada como la diferencia en pendiente y punto de corte relativo de los modelos lineales de ajuste entre dos puntos de quiebre. Por otra parte, a diferencia del modelo propuesto por Haywood y Randal (2008), la componente de estacionalidad es estimada de la siguiente forma:

$$S_t = \sum_{i=1}^{s-1} \gamma_{i,j}(d_{t,i} - d_{t,0})$$

En cuyo caso, si t corresponde a la estacionalidad 0, entonces $d_{t,i} - d_{t,0} = -1$, y para todas las demás estacionalidades $d_{t,i} - d_{t,0} = 1$. En este caso, $d_{t,i}$ es una amplitud de estacionalidad que es relativa a la estacionalidad base. De este modo, el propuesto iterativo propuesto por Verbesselt et al. (2010) para la implementación de BFAST incluye los siguientes pasos:

1. Si la implementación de la prueba de Cuadrados Mínimos Ordinarios de la Suma basados en Residuos Móviles (OLS-MOSUM) indica que los puntos de quiebres

ocurren en el componente de tendencia, el número y posición de los puntos de quiebre de tendencia son estimados desde los datos ajustados de estacionalidad,

$$Y_t - \hat{S}_t$$

2. Los coeficientes de tendencia son calculados basados en M-estimación (Venables y Ripley 2013).
3. Si la prueba OLS-MOSUM indica que los puntos de quiebre ocurren en la componente estacional, la posición y el número de puntos de quiebre son determinados tomando como referencia la tendencia $Y_t - \hat{T}_t$
4. Los coeficientes de estacionalidad son calculados en base a M-estimación.

Este proceso se ejecuta de forma iterativa hasta que el número de puntos de quiebre y sus posiciones resultan invariantes. Desde este enfoque, el algoritmo BFAST generará alertas del QE más importante dentro de un periodo de estudio. Con este enfoque, se tendrá seguridad, que los QE detectados por BFAST son los más significativos del periodo de observación.

Para los fines de esta propuesta de investigación, esta revisión de la literatura ha permitido concluir que BFAST, además de ser derivado de enfoques metodológicos conocidos en el área de la econometría para la detección de QE, presenta mejoras significativas, que permiten obtener más información y confiabilidad para la detección de QE. También, es importante mencionar, que su implementación en lenguaje R, mediante el uso de la librería BfastSpatial, proporciona gráficas que facilitan evaluar la recuperación de la serie temporal una vez detectado un QE. Por estas razones, se ha escogido este algoritmo para el diseño metodológico orientado a presentar respuestas al problema de investigación de esta tesis.

Por su parte, en referencia a la implementación de CUSUM, es pertinente señalar que, Strucchange es un paquete de R especializado para la detección de estructurales en series temporales. Entre las pruebas incluidos para la detección de quiebres resaltan la prueba F (Test de Chow), Sumas Acumuladas (CUSUM) y Sumas de Medias Móviles (MOSUM). Con base en el hecho de que, BFAST es un algoritmo que deriva de CUSUM, para este trabajo de investigación se ha seleccionado la implementación de CUSUM a partir del paquete Strucchange, para generar un marco de referencia que permita comparar los resultados generados por BFAST

CUSUM se fundamenta en la suma acumulada de residuos estandarizados, considerando la siguiente ecuación:

$$W_n(t) = \frac{1}{\tilde{\sigma}\sqrt{\eta}} \sum_{i=k+1}^{k+[t_\eta]} \tilde{u}_i \quad (0 \leq t \leq 1)$$

Donde $\eta = n - k$ es el número de residuos recursivos y $[t_\eta]$ es la parte entera de t_η . Bajo la hipótesis nula, el límite del proceso de fluctuaciones empíricas $W_n(t)$, es el Movimiento Browniano Estándar (También conocido como Proceso de Wiener). De este modo, el teorema central del límite establece que:

$$W_n \Rightarrow W$$

En la medida en que $n \rightarrow \infty$, el operador \Rightarrow denota una convergencia débil de las medidas de probabilidad asociadas.

Ahora bien, bajo la hipótesis alternativa, si existe un quiebre estructural en el punto t_o , los residuos recursivos solo tendrán media cero hasta t_o . Por lo tanto, el algoritmo demanda que la media será cercana a cero hasta t_o , y luego tomar una media distinta a partir de las sumas de residuos acumulados. En Strucchange, este proceso se hace de modo recursivo, para obtener varios quiebres. (Zeileis et al. 2003)

Capítulo tercero

Análisis de resultados

En este capítulo, se presentan los resultados obtenidos durante las etapas de pre-procesamiento de los datos, detección de quiebres estructurales, y análisis de relaciones entre quiebres detectados para el periodo 2019-2022 y la pandemia del COVID-19.

1. Resultados de la etapa de Pre-procesamiento de los datos

El pre-procesamiento de los datos fue realizado a partir del desarrollo e implementación de 3 scripts en el lenguaje de programación Python. A continuación, se describe el propósito de cada uno de estos scripts:

1.1 main.py

Este script es el primero en el orden de ejecución (Anexo 1). Su primera tarea es la de realizar la lectura de los archivos Excel proporcionados por la Bolsa de Valores de Quito con las series temporales de precios de cierre diarios. Es importante mencionar, que los archivos colectados se obtuvieron para todos los años desde enero de 2013 hasta diciembre de 2022. Distribuidos en un formato anual, en el que cada uno de estos archivos contenían el precio de cierre diario para todas las empresas que tuvieron transacciones para cada día. Los archivos son leídos en formato “dataframe” utilizando la librería pandas de Python.

Una vez que son leídos cada uno de los archivos anuales, el script implementa varios filtros. Los archivos anuales contienen empresas que cotizan tanto en la Bolsa de Valores de Guayaquil, así como también las empresas que cotizan en la Bolsa de Valores de Quito. El primer filtro que implementa el script main.py, es el de omitir del conjunto de datos todas las empresas que cotizan en la Bolsa de Valores de Guayaquil.

Los archivos anuales originales, contienen 8 columnas a saber: Fecha, Emisor, Valor, Valor Nominal, Precio, Numero Acciones, Valor Efectivo, Y Procedencia. De estas columnas, las únicas que son relevantes para los objetivos de este estudio son Fecha, Emisor y Precio. De este modo, el segundo filtro implementado por main.py, consiste en seleccionar exclusivamente estas tres columnas, y desechar el resto.

Uno de los primeros hallazgos alcanzados durante el análisis de las series temporales, es el hecho de que pocas empresas transaccionan acciones con frecuencia diaria en la Bolsa de Valores de Quito. Este hallazgo, permitió establecer el criterio para definir la lista corta de las 10 empresas que serían consideradas para este estudio. Para esto, el tercer filtro implementado en `main.py`, consistió en determinar el número de días en el que se transaccionaron acciones por cada empresa y por cada año en la Bolsa de Valores de Quito. De este modo, se creó una lista jerárquica, por cada año, en el que se ordenaron las empresas de acuerdo con el número de días que hubo transacciones en el año.

Tomando en consideración que las series de cotización diarias presentan una gran diversidad de datos faltantes entre las empresas que cotizan en la Bolsa de Valores de Quito, y en aras de maximizar la comparación entre las series temporales de cotización de las empresas, el cuarto filtro implementado por `main.py` fue el calcular el precio promedio mensual de cotización de cada una de las empresas por cada año. El quinto filtro consistió en fusionar los 10 dataframes correspondientes a los años que van desde 2013 hasta 2022. El sexto filtro consistió en generar una lista jerárquica del número de meses en el que cotizaron las empresas en la Bolsa de Valores de Quito.

En la tabla 1., se muestran las 10 primeras empresas de acuerdo con el mayor número de meses con cotización en la Bolsa de Valores de Quito, durante el periodo enero de 2013 hasta diciembre de 2022. En esta tabla se reflejan en total de meses donde al menos hubo una transacción de compraventa de acciones para cada empresa, con la etiqueta “COTIZACIONES”.

También se muestra la fecha de la primera cotización dentro del periodo de estudio (Las empresas cuya FECHA INICIO sea 01/01/2013, son empresas que han estado cotizando en fechas previas. Sin embargo, se define esta fecha para realizar el conteo de meses que debe tener cada empresa, de acuerdo con la fecha en la que empezó a cotizar.). Finalmente, en la columna etiquetada como “FALTANTE”, se observan el número de meses en donde no hubo ninguna transacción para cada empresa, calculado como la diferencia entre; el total de meses que hay desde la fecha de inicio de cotización de cada empresa y diciembre de 2022, y el número de cotizaciones expresadas en la segunda columna de la tabla. Se puede apreciar que la variabilidad entre números de cotizaciones faltantes es muy variada, y por ende ha sido necesario aplicar un proceso de interpolación.

Tabla 1
Empresas por número de meses con cotización en la BVQ desde enero 2013 hasta diciembre de 2022

Emisor	Cotizaciones	Fecha Inicio	Faltantes
Corporación Favorita	120	01/01/2013	0
Banco Guayaquil	119	01/01/2013	6
Holcim Ecuador	112	01/01/2013	13
Banco Pichincha	106	01/01/2013	19
Produbanco	93	01/01/2013	32
Cervecería Nacional	86	01/03/2015	12
San Carlos	77	01/01/2013	48
Bvq	55	01/02/2018	9
Industrias Ales	54	01/01/2013	71
Mutualista Pichincha	53	01/01/2017	12

Fuente y elaboración propias.

1.2 Interpolador.py

Este script (Anexo 2), tiene por objeto completar las cotizaciones faltantes en las series temporales de las 10 empresas seleccionadas, a partir de un proceso de interpolación. Para lograr esta tarea de modo exitoso, fue necesario garantizar que el método de interpolación aplicado no incluyera sesgo ni creara distorsiones en la información real de las series temporales. Para lograr esto, se utilizó el método “pad” de la librería pandas de Python. Este método, rellena cada dato faltante en la serie temporal con el último dato conocido disponible. De este modo, cuando hay datos faltantes, son rellenados con el último dato de cotización disponible para cada empresa.

El resultado de la implementación de Interpolador.py es un archivo CSV para cada empresa, conformado por las columnas “FECHA” y “PRECIO”, y con una serie temporal completa desde la fecha de cotización inicial hasta la fecha de cierre del periodo de estudio. Si bien, las serie temporales proporcionan datos desde enero de 2013, hasta diciembre de 2022, es importante destacar que los análisis de quiebres estructurales han sido previstos para realizarlos en el periodo enero de 2019 hasta diciembre de 2022.

1.3 Fusion.py

Este script (Anexo 3), toma los archivos CSV de cada empresa, y lo fusiona en un único archivo, en el que la primera columna es la fecha, y le siguen 10 columnas con los precios de cotización de cada empresa. La salida de este script es un archivo CSV, en el que están contenidas las series temporales de las 10 empresas seleccionadas.

2. Detección de Quiebres Estructurales.

2.1. Estadística Descriptiva

En la siguiente tabla se presentan la estadística descriptiva de los precios de las acciones por sector. Como se puede observar, en el sector financiero el COVID no tuvo un efecto homogéneo entre las diferentes entidades. Banco de Guayaquil, BVQ y Mutualista Pichincha registraron un precio medio mayor en la fase POST-COVID. En cuanto a la volatilidad se puede observar mayor variación en la época de POST-COVID en comparación con las fases PRE-COVID y COVID. Por otra parte, en el sector productivo y comercial se puede observar una reducción del precio promedio desde el COVID, hasta el POST-COVID, en este sector llama la atención la alta volatilidad de Cervecería Nacional.

2.2. Detección de Quiebres para el periodo 2019-2022

En esta sección, se presentan los resultados de quiebres obtenidos por los algoritmos BFAST y CUSUM para el periodo de estudio comprendido entre enero de 2019 y diciembre de 2022. El periodo PRE-COVID corresponde al periodo enero-diciembre de 2019, el periodo COVID corresponde al periodo enero-diciembre 2020, y el periodo POST-COVID corresponde al periodo enero 2021 a diciembre 2022.

Tabla 2

Estadística descriptiva del precio de cotización de acciones durante los periodos PRE-COVID (2019), COVID (2020) y POST-COVID (2021-2022)

Sector	Empresa	Pre-Covid (2019)		Covid (2020)		Post-Covid (2021-2022)	
		Media	Desv. Est.	Media	Desv. Est.	Media	Desv. Est.
Sector Financiero	Banco Guayaquil	0,90	0,06	0,89	0,08	0,95	0,08
	Banco Pichincha	91,92	5,62	89,42	2,54	84,59	6,67
	BVQ	1,07	0,04	1,09	0,07	1,40	0,28
	Produbanco	0,74	0,05	0,76	0,07	0,67	0,07
	Mutualista Pichincha	88,95	9,60	88,93	8,00	98,42	2,21
Sector Productivo y Comercial	Cervecería Nacional	89,50	3,32	90,65	2,53	66,32	11,81
	Holcim	61,33	5,35	57,75	2,39	50,90	4,76
	Industrias Ales	0,50	0,00	0,45	0,03	0,39	0,03
	San Carlos	0,67	0,02	0,65	0,00	0,63	0,04
	Corporación Favorita	2,50	0,10	2,36	0,00	2,27	0,10

Fuente y elaboración propias.

En este contexto, a continuación, se presentan los quiebres estructurales por sectores obtenidos mediante ambos algoritmos, para cada uno de los periodos considerados en el estudio.

2.2.1. Sector Financiero

A. Contexto general de las empresas del sector financiero.

La tabla 2 muestra que, durante el periodo de estudio, 3 empresas experimentaron aumento en el precio medio de cotización de sus acciones (Banco Guayaquil, BVQ, y Mutualista Pichincha), y 2 empresas experimentaron bajas es sus precios medios de cotización.

B. Resultados algoritmo CUSUM para el sector Financiero

La figura 8, muestra los quiebres obtenidos para cada una de las empresas del sector financiero mediante el algoritmo CUSUM. Con fines ilustrativos, se han resaltado en diferentes colores los periodos de análisis de esta investigación. Las líneas verticales representan los quiebres estructurales detectados. El color azul corresponde a quiebres estructurales positivos, en donde aumenta el precio de cotización, y el color rojo a quiebres estructurales negativos, en donde disminuye el precio de cotización.

En la figura 8.a. se observa un quiebre estructural positivo para el banco Guayaquil en el periodo POST-COVID. El precio de cotización del banco Guayaquil evidencia algunas oscilaciones, pero el precio promedio se mantuvo cercano al valor de cotización al inicio de la pandemia. A partir de este quiebre estructural, el precio de cotización aumentó progresivamente, hasta el final del periodo de estudio.

La figura 8.b. muestra que CUSUM detectó dos quiebres para el Banco Pichincha en el periodo de estudio. El primer quiebre es positivo en periodo PRE-COVID, y el segundo es negativo en periodo POST-COVID. Durante la pandemia, el precio de cotización se mantuvo alrededor del precio inicial, pero durante el periodo POST-COVID, después del quiebre detectado, el precio de cotización disminuyó lentamente hasta el final del periodo de estudio.

La figura 8.c. muestra que, para Produbanco CUSUM detectó un quiebre positivo en la etapa de PRE-COVID. Aunque la gráfica del precio de cotización medio durante las fases COVID y POST-COVID muestran oscilaciones importantes, CUSUM no detectó quiebres estructurales para ninguna de estas fases.

La figura 8.d. muestra que, para la Mutualista Pichincha fueron detectado 3 quiebres durante el periodo de estudio. Uno negativo en la fase PRE-COVID, uno positivo en la fase COVID, y uno positivo en la fase POST-COVID. De modo similar al Banco Guayaquil y al Banco Pichincha, el precio de cotización de la Mutualista Pichincha se caracteriza por una caída importante durante la fase PRE-COVID. Sin embargo, a mediados del 2020, durante la fase COVID, experimentó un aumento que se prolongó hasta finales del periodo de estudio. La mutualista Pichincha cierra al final del periodo de estudio con un crecimiento en el precio de cotización, en comparación con el precio medio de la acción durante la fase PRE-COVID.

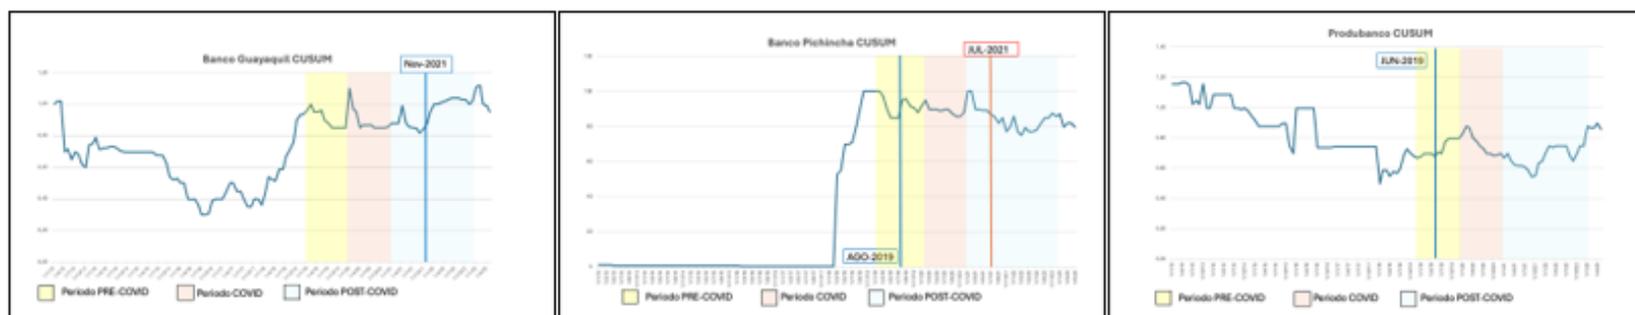
La figura 8.e. muestra que, en el caso de la Bolsa de Valores de Quito, se detectaron 3 quiebres estructurales positivos, uno para cada fase del estudio. Si bien, se aprecia que el precio de cotización aumenta tanto en la fase PRE-COVID como en la fase COVID. En la fase POST-COVID el aumento es notablemente más pronunciado.

C. Resultados algoritmos BFAST para el sector Financiero.

La figura 9, muestra los quiebres obtenidos para cada una de las empresas del sector financiero mediante el algoritmo BFAST. En la figura 9.a se muestra que, para el caso del Banco Guayaquil BFAST no detectó quiebres estructurales para ninguna fase del periodo de estudio. La figura 9.b. muestra por su parte que el algoritmo BFAST detectó un quiebre estructural negativo para la fase POST-COVID.

Para el caso de Produbanco, la figura 9.c. evidencia que BFAST detectó un quiebre estructural negativo a inicios de la fase COVID, y un quiebre estructural positivo en la fase POST-COVID. En la figura 9.d. se observa que, BFAST detecta un quiebre estructural negativo en la fase PRE-COVID para la Mutualista Pichincha. También se observan un quiebre positivo para la fase de COVID, y un quiebre positivo para la fase POST-COVID.

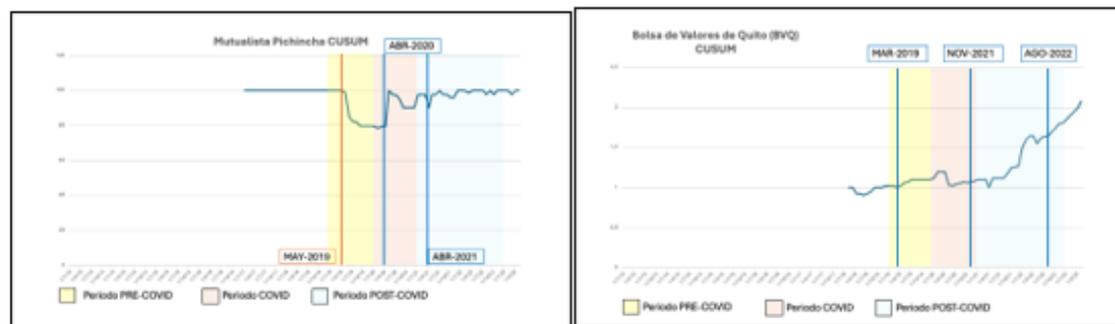
En la figura 9.e. se observa que, BFAST detectó un quiebre estructural negativo en la fase de COVID para la Bolsa de Valores de Quito. También detectó dos quiebres positivos para la fase POST-COVID.



a) Banco de Guayaquil

b) Banco Pichincha

c) Produbanco

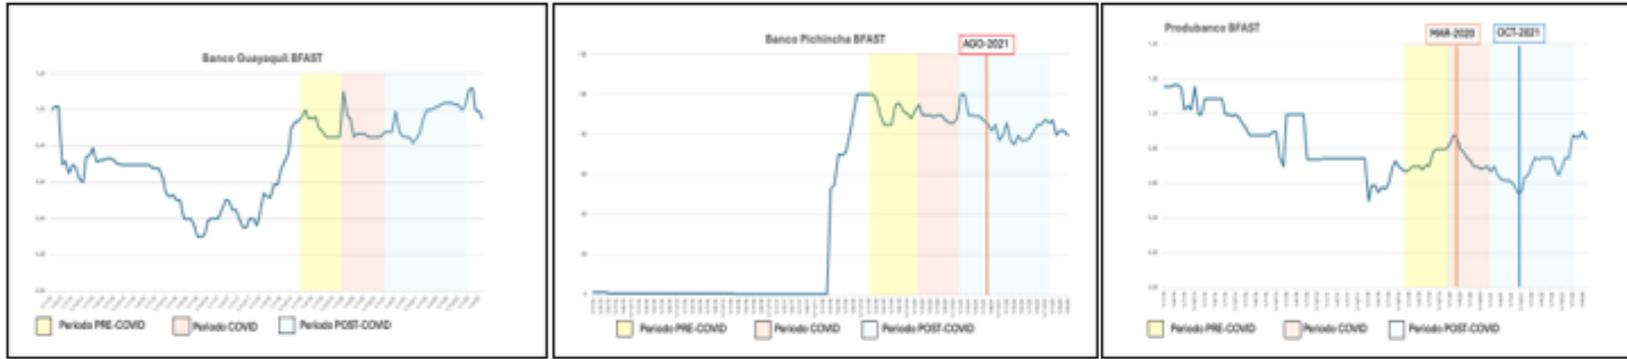


d) Mutualista Pichincha

e) Bolsa de Valores de Quito

Figura 8. Resultados de quiebres para el sector financiero mediante CUSUM..

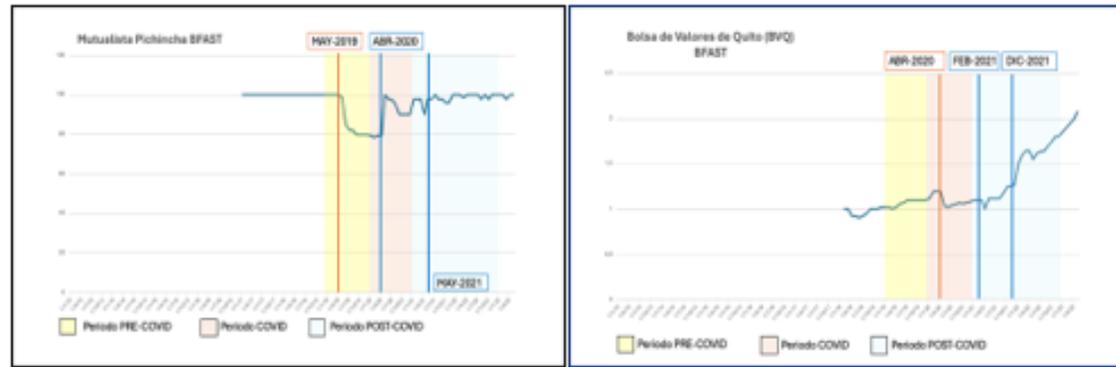
Fuente y elaboración propias.



a) Banco de Guayaquil

b) Banco Pichincha

c) Produbanco



d) Mutualista Pichincha

e) Bolsa de Valores de Quito

Figura 9. Resultados de quiebres para el sector financiero mediante BFAST.

Fuente y elaboración: Propias.

2.2.2. Sector Productivo y Comercial

A. Contexto general de las empresas de sectores productivo y comercial

Las 5 empresas incluidas en el sector productivo y comercial son Cervecería Nacional, Holcim, Industrias Ales, San Carlos y Corporación Favorita, las cuales experimentaron bajas en el precio medio de cotización de sus acciones durante las fases COVID y POST-COVID.

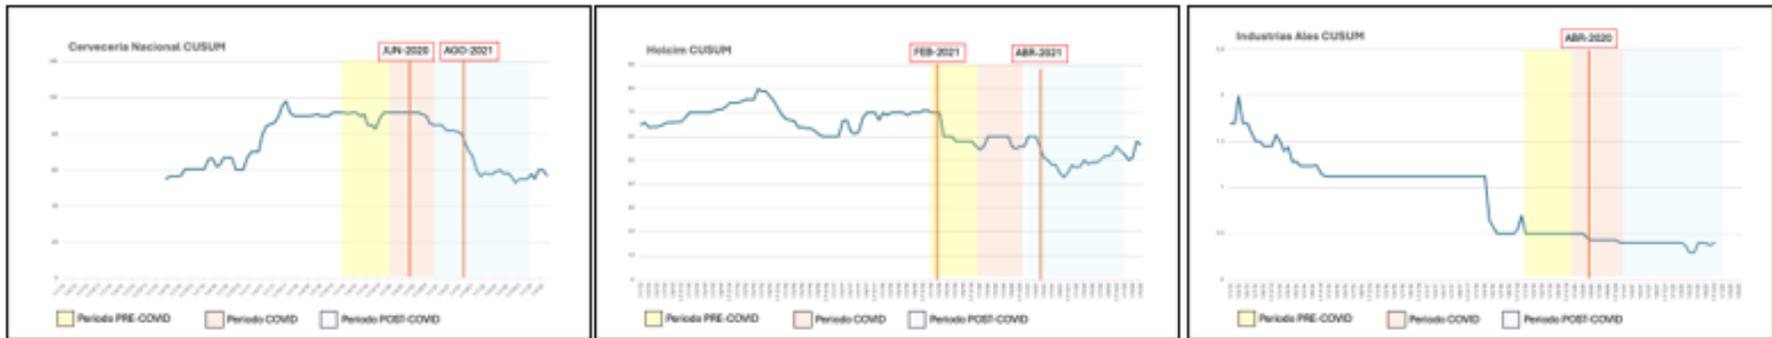
B. Resultados algoritmo CUSUM para sectores Productivo y Comercial

La figura 10, muestra los quiebres obtenidos para cada una de las empresas de los sectores productivo y comercial mediante el algoritmo CUSUM. Se observa en la figura 10.a. que, el algoritmo detectó en total dos quiebres estructurales negativos para Cervecería Nacional. El primer quiebre negativo fue detectado en la fase COVID, mientras que el segundo quiebre negativo fue detectado en la fase POST-COVID, este último vinculado a una caída profunda en el precio medio de cotización de la acción de Cervecería Nacional.

La figura 10.b. muestra que, fueron detectados dos quiebres negativos para Holcim. El primer quiebre negativo fue detectado en el inicio de la fase PRE-COVID, mientras que el segundo quiebre negativo fue detectado en la fase POST-COVID. Si bien, este quiebre está asociado con una caída en el precio medio de la acción de Holcim, la gráfica muestra una recuperación en el precio medio de la acción a finales de la fase POST-COVID, pero esta recuperación no es captada por CUSUM como un quiebre.

La figura 10.c. muestra que, CUSUM detectó un quiebre estructural en la fase COVID para Industrias Ales. Este quiebre tiene una magnitud baja, y es importante mencionar, que se encuentra dentro de la tendencia que muestra la serie temporal. La figura 10.d. evidencia que, CUSUM no detectó quiebres estructurales para la serie temporal de San Carlos.

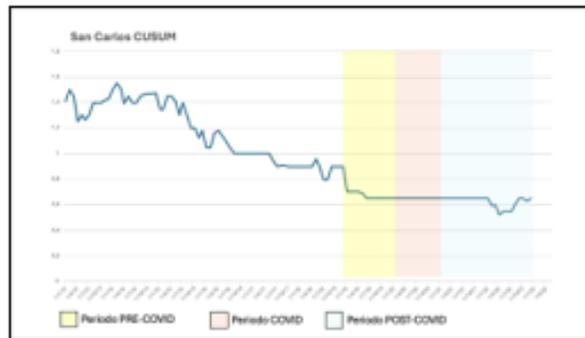
La figura 10.e. permite observar que, CUSUM detectó un quiebre estructural negativo en la fase COVID para Corporación Favorita. Este quiebre está dentro de la tendencia de la serie temporal, y no representa un cambio permanente en el comportamiento del precio medio de la acción.



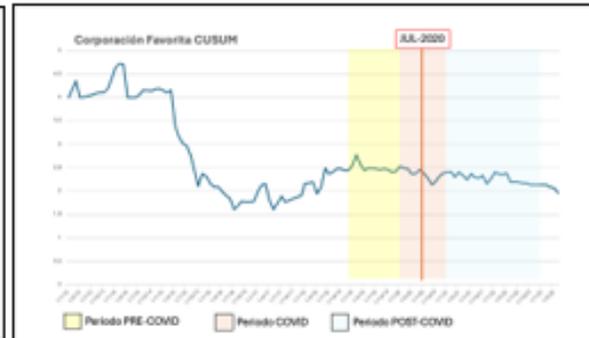
a) Cervecería Nacional

b) Holcim

c) Industrias Ales



d) San Carlos



e) Corporación La Favorita

Figura 10. Resultados de quiebres para el sectores productivos y comercial mediante CUSUM.
Fuente y elaboración: Propias.

C. Resultados algoritmo BFAST para sectores Productivo y Comercial

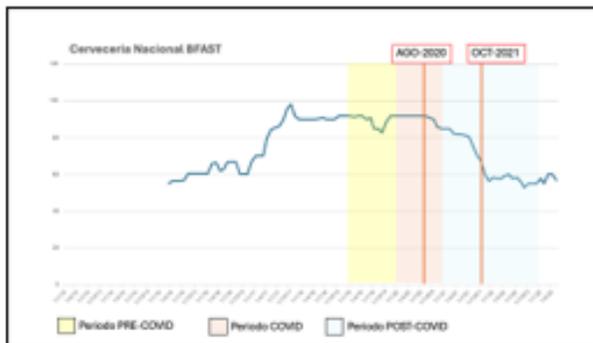
La figura 11, muestra los quiebres obtenidos para cada una de las empresas de los sectores productivo y comercial mediante el algoritmo BFAST. La figura 11.a. muestra que, este algoritmo detectó dos quiebres estructurales negativos para Cervecería Nacional. De modo similar a los resultados obtenidos por CUSUM para Cervecería Nacional, BFAST detecta un quiebre negativo durante la fase COVID, y un quiebre negativo para la fase POST-COVID.

Por otra parte, BFAST detectó dos quiebres negativos para Holcim, durante las fases de PRE-COVID y COVID. Mientras que para la fase POST-COVID detectó un quiebre estructural positivo (ver figura 11.b.). Este quiebre positivo detectado por BFAST, difiere del quiebre estructural negativo detectado por CUSUM durante la fase POST-COVID para Holcim, únicamente en la fecha de detección. Mientras que CUSUM detectó el quiebre en abril de 2021, donde la tendencia de precio continuaba en baja, BFAST detectó el quiebre en octubre de 2021, fecha a partir de la cual cambió la tendencia de precios medios de la acción de Holcim. Los resultados de quiebres obtenidos por BFAST permite describir de modo más preciso el comportamiento observado en comparación con CUSUM, debido a que están relacionados con cambios de tendencias en el comportamiento del precio de cotización de las acciones.

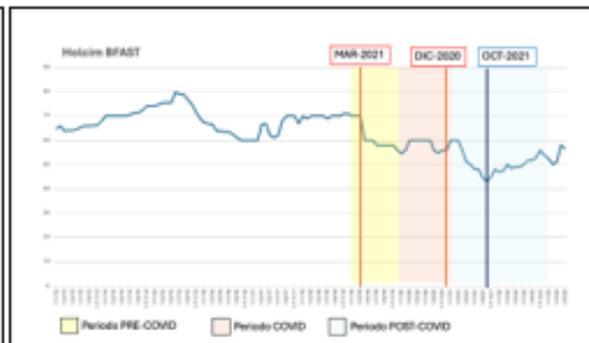
La figura 11.c. muestra que, BFAST detectó un quiebre para la fase POST-COVID de Industrias Ales. Este quiebre está asociado con el único cambio de tendencia observado en la serie temporal de Industrias Ales durante el periodo 2019-2022. Es importante destacar que, si bien Industrias Ales cierra el periodo de estudio en baja respecto al inicio de la fase PRE-COVID, BFAST detectó un cambio de tendencia al final de la fase POST-COVID.

La figura 11.d. muestra que, BFAST detectó un quiebre para la fase POST-COVID de San Carlos. Este quiebre está asociado con el único cambio de tendencia observado en la serie temporal de San Carlos durante el periodo 2019-2022. Es importante destacar que, si bien San Carlos cierra el periodo de estudio en baja respecto al inicio de la fase PRE-COVID, BFAST detectó un cambio de tendencia al final de la fase POST-COVID.

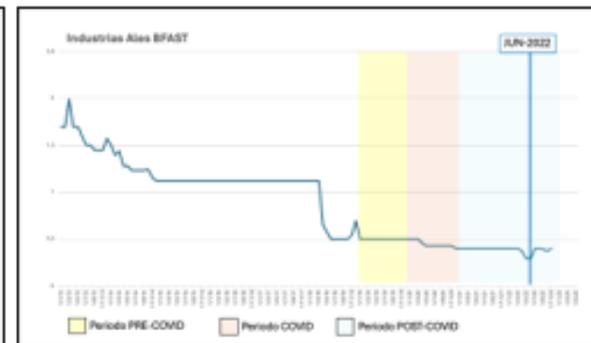
Finalmente, la figura 11.e. muestra que, BFAST no detectó quiebres estructurales en la serie temporal de Corporación Favorita.



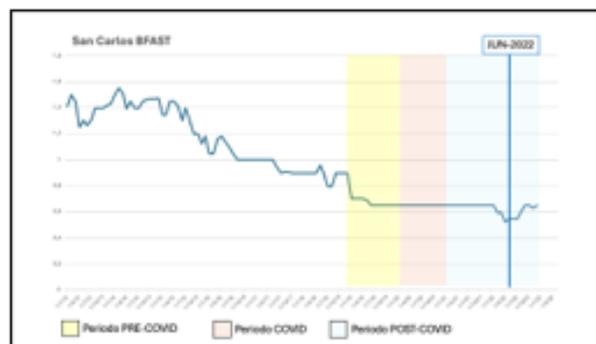
a) Cervecería Nacional



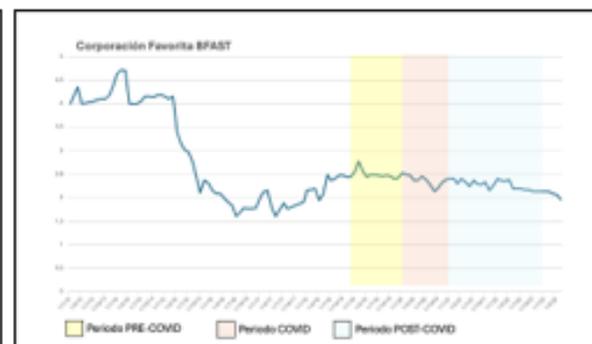
b) Holcim



c) Industrias Ales



d) San Carlos



e) Corporación La Favorita

Figura 11. Resultados de quiebras para el sectores productivos y comercial mediante BFAST.

Fuente y elaboración: Propias.

3. Análisis de Anomalías y Recuperación de Precios de Cotización a Consecuencia del COVID-19

Entre el conjunto de resultados esperados de este trabajo de investigación, resalta la caracterización de anomalías detectadas durante la fase del COVID-19, y la recuperación de precios. Este punto, es desarrollado en esta sección a continuación.

3.1. Anomalías y Recuperación de Precios en el Sector Financiero

Durante 2019, el Ecuador experimentó una desaceleración de 1,2% en el Producto Interno Bruto (PIB) respecto al 2018; en el mes de octubre de este mismo año, hubo un paro nacional que ralentizó todos los componentes de la demanda agregada, desaceleró la inversión y el consumo privado. Además, se reportó un aumento déficit fiscal como consecuencia de la baja de los precios petroleros y de la recaudación tributaria (CEPAL 2020, 1). Este escenario, preparó las condiciones para que, en el primer semestre de 2019, fase PRE-COVID, las acciones del Banco Guayaquil, Banco Pichincha, y Mutualista Pichincha presenten una disminución significativa de los precios. Es interesante mencionar, que los precios de cotización de Produbanco y de la Bolsa de Valores de Quito aumentaron ligeramente, y no mostraron caídas durante esta fase.

La explicación para estas diferencias es por una parte, la Bolsa de Valores de Quito aunque está clasificada en el sector financiero, ejerce una actividad muy diferente a las 4 entidades bancarias incluidas en este sector. Mientras que Produbanco, venía experimentando una baja desde enero de 2013, y al inicio de 2019 sus acciones cotizaban a un valor muy por debajo del promedio del mercado. Debido a esta naturaleza, la fase COVID, no tuvo un impacto significativo para la Bolsa de Valores de Quito y para Produbanco. Durante la fase COVID la Bolsa de Valores de Quito experimentó un ligero crecimiento, mientras que, Produbanco mostró un crecimiento significativo en el precio de sus acciones.

Por otra parte, el banco Guayaquil ingresó a la fase COVID con una recuperación total de los efectos de 2019, y a consecuencia de la pandemia experimentó un decrecimiento que llevó el precio de sus acciones a los niveles bajos experimentados durante 2019, este nivel bajo de precios se mantuvo durante toda la fase del COVID. El Banco Pichincha, entró con niveles bajos a la fase COVID en comparación con enero de 2019, posteriormente el precio de sus acciones continuó con tendencia de baja durante todo 2020. La Mutualista Pichincha experimentó un crecimiento al inicio de la fase del COVID, sin embargo, este aumento no fue sostenible, mostrando fluctuaciones durante

2020. Sin embargo, el precio de cotización de la Mutualista Pichincha creció durante la fase de COVID, y entró a la fase POST-COVID con una tendencia de alza.

En la fase POST-COVID, el Banco Guayaquil mostró recuperación de precios, que superaron máximos históricos. El Banco Pichincha, experimentó un alza a inicio de esta fase, pero no fue sostenible y cerró en 2022 con una tendencia a la baja. El Banco Pichincha no mostró recuperación, y su precio de cotización cerró en el periodo POST-COVID con valores inferiores a los que ingresó a la fase PRE-COVID. Por su parte Produbanco, inició un proceso de recuperación en el tercer trimestre de 2021, que se mantuvo hasta el cierre de diciembre de 2022. La Mutualista Pichincha continuó con su tendencia suave de alza hasta cerrar la fase POST-COVID con un valor de cotización similar, al reportado al inicio de la fase PRE-COVID. La Bolsa de Valores de Quito, experimentó un crecimiento superior al 40% desde el inicio de la fase POST-COVID, y este crecimiento se mantuvo al cierre de esta fase.

Por lo expuesto, se puede afirmar que no existe un comportamiento común entre las entidades que componen este sector; por el contrario, cada entidad muestra y comportamiento distinto.

3.2. Anomalías y Recuperación de Precios en el Sector Productivo y Comercial

De modo similar al sector financiero, las empresas de este sector experimentan una tendencia de baja desde 2019. Las gráficas de series temporales de los precios medios mensuales de cotización no muestran evidencias de un impacto significativo durante el COVID 19. Las tendencias de baja en este sector se mantuvieron tanto en las fases PRE-COVID como COVID, sin anomalías aparentes como consecuencia de la pandemia.

Ahora bien, durante la fase POST-COVID, es importante resaltar que Holcim experimenta una caída significativa al inicio de esta fase, y luego experimenta una recuperación de precios en el segundo semestre de 2021. Esta caída puede estar relacionada con las afectaciones que sufrió el mercado inmobiliario y de la construcción a consecuencia del estado de emergencia nacional y limitaciones de movilidad.

Por su parte, Cervecería Nacional experimentó caídas durante la fase POST-COVID que llevaron su precio de cotización a récords de mínimo histórico. Al final del periodo estudio, el precio de cotización se estabilizó alrededor de este mínimo histórico sin mostrar indicios de recuperación. Para el resto de las empresas de este sector, se mantuvo la tendencia de baja durante la fase POST-COVID.

De manera general, en este sector se manifestó un comportamiento decreciente en el precio de las acciones, los cuales se detectaron en su mayoría con los algoritmos estimados.

Capítulo cuarto

Discusión de Resultados

Los resultados obtenidos mediante la implementación del algoritmo BFAST, en el contexto de esta investigación, se pueden resaltar en dos aspectos: i) en la identificación del impacto del COVID-19 y ii) en la detección de la recuperación en la fase POST-COVID, para la 10 empresas incluidas en el estudio. Los resultados obtenidos y reportados en el capítulo tercero se pueden resumir a partir de estos dos segmentos.

1. Impacto ocasionado por el COVID-19

La identificación de rasgos vinculados al impacto que la pandemia COVID-19 ocasionó en el precio de cotización mensual medio de las acciones de las empresas incluidas en este estudio, se ha realizado mediante la detección de quiebres estructurales durante la fase COVID, así como también con la comprobación de cambio de tendencia asociado al quiebre estructural detectado.

Para el sector financiero, BFAST detectó quiebres estructurales durante la fase COVID únicamente para Produbanco y para la Bolsa de Valores de Quito, ambos con asociados con cambios de tendencia. El análisis de los datos muestra que ambas empresas experimentaron caídas estructurales en el precio de sus acciones; en el mes de febrero para la Bolsa de Valores de Quito, y en marzo para Produbanco.

A partir de este estudio se deduce que no hay evidencias de impactos asociados con el COVID-19 para el Banco Guayaquil, Banco Pichincha, ni Mutualista Pichincha. Es pertinente destacar, que para la Mutualista Pichincha, BFAST detectó un quiebre estructural positivo para abril de 2020. Sin embargo, este quiebre estructural y su tendencia no muestran relación con la pandemia COVID-19.

Para el sector productivo y comercial, BFAST detectó quiebres estructurales asociados con cambios de tendencia para Cervecería Nacional en agosto de 2020, y para Holcim en diciembre de 2020. Para las empresas Industrias Ales, San Carlos y Corporación la Favorita, no se detectaron evidencias significativas de impacto del COVID-19.

A diferencia del sector financiero, en donde las empresas Produbanco y Bolsa de Valores de Quito mostraban una tendencia de alto al momento del Quiebre Estructural;

tanto Cervecería Nacional, como Holcim mostraron una tendencia neutra durante la fase PRE-COVID y la fase COVID, hasta la aparición del Quiebre Estructural. Esto evidencia, que en este sector productivo y comercial los efectos del COVID-19 tuvieron un retraso en evidenciarse, en comparación con el sector financiero.

2. Recuperación en fase POST-COVID

La detección de rasgos de recuperación de precios en las acciones, se realizó siguiendo el mismo enfoque metodológico utilizado para el análisis de impacto, pero esta vez analizando la fase POST-COVID. En este contexto, en el sector financiero, tanto Produbanco como la Bolsa de Valores de Quito, mostraron recuperación de precios durante la fase POST-COVID. En el caso de Produbanco, la tendencia de caída iniciada con el QE de marzo de 2020, finalizó con un QE detectado durante fase POST-COVID en octubre de 2021. Al finalizar el periodo POST-COVID, el valor de cotización de Produbanco fue superior que al inicio del periodo PRE-COVID.

Para la Bolsa de Valores de Quito, la recuperación fue más notable aún; se detectó un QE positivo para febrero de 2021, y un segundo QE positivo para diciembre de 2021. La Bolsa de Valores de Quito cierra al final de la fase POST-COVID mostrando un máximo histórico en el precio de cotización.

En referencia al sector productivo y comercial, para Cervecería Nacional se detectó un QE de profundización en octubre de 2021, para el que posteriormente hubo un cambio de tendencia. Cervecería Nacional no mostró recuperación de precios para el final de la fase POST-COVID, pero sí mostró la culminación de la tendencia de caída.

Para Holcim se detectó un QE positivo en fase POST-COVID para octubre de 2021, relacionado con el fin de la tendencia de caída. A partir de este QE dio inicio la recuperación de precios para esta empresa. Sin embargo, para el cierre del periodo de estudio de esta investigación, Holcim cotizaba en valores inferiores a los mostrados al inicio de la fase PRE-COVID. De este modo, se destaca que si bien hubo recuperación en los precios de cotización de Holcim, no se alcanzaron los niveles exhibidos al inicio de la fase PRE-COVID.

3. Comparación de los resultados obtenidos

Teniendo en consideración que la serie histórica utilizada en este estudio es solo de 10 años, misma que inicia en enero de 2013 y culmina en diciembre de 2022, es de

alta relevancia analizar las analogías y diferencias que pueden identificarse, al comparar los resultados obtenidos con el de trabajos relacionados.

En el contexto internacional, diversos autores coinciden en el hecho de que los efectos ocasionados por el COVID-19 a los mercados de valores internacionales, superan de modo contundente a los de eventos análogos que ocurrieron en el pasado, tales como la fiebre española de 1918, la influenza del 57, o la influenza del 68 (Baker et al. 2020). Es interesante destacar, que el análisis realizado por Baker et al. (2020), no permitió relacionar los efectos del COVID-19 con la letalidad del virus, ya que al momento de su estudio las muertes ocasionadas por el COVID-19 eran 25 veces menores que las ocasionadas por la fiebre española de 1918. Los autores asociaron el impacto del COVID-19 con el rápido acceso a información y a noticias con el que cuenta la población mundial en la actualidad.

Este resultado, tiene una alineación directa con lo ocurrido en el mercado de valores del Ecuador. De acuerdo con el boletín especial de la Secretaría General de Comunicación de la Presidencia del Ecuador, el caso cero de COVID-19 se reporta el 27 de febrero de 2020 (<https://www.comunicacion.gob.ec/se-registra-el-primer-caso-de-coronavirus-en-ecuador/>). Consecuentemente, los quiebres estructurales para el sector financiero se detectan en el mes de febrero para la Bolsa de Valores de Quito, y en marzo para Produbanco. Desde el reporte de este caso cero, no hay evidencias de crecimiento para ninguna de las empresas incluidas en este estudio.

La figura 12 muestra los índices bursátiles de 6 países de la región, durante los meses de febrero a mayo de 2020 (Mendoza-Rivera et al. 2020). En todos los casos, aunque de modo más suave en Perú, se observa un comportamiento cóncavo en los índices bursátiles, cuya tendencia de caída se profundiza en marzo de 2020. En el caso de Brasil y Chile las caídas observadas en marzo están en el orden del 40%. Las caídas experimentadas por Argentina, México y Colombia están entre un 20% y 50%. Por su parte Perú, evidenció una caída de aproximadamente 20%. Estos resultados, son consistentes con la detección de los QE obtenidos para el sector financiero de la Bolsa de Valores de Quito. Es importante destacar, que la caída más fuerte de la Bolsa de Valores de Quito ocurrió en abril de 2020, cuya escala temporal está dentro del rango de efectos mostrados en la figura 13.

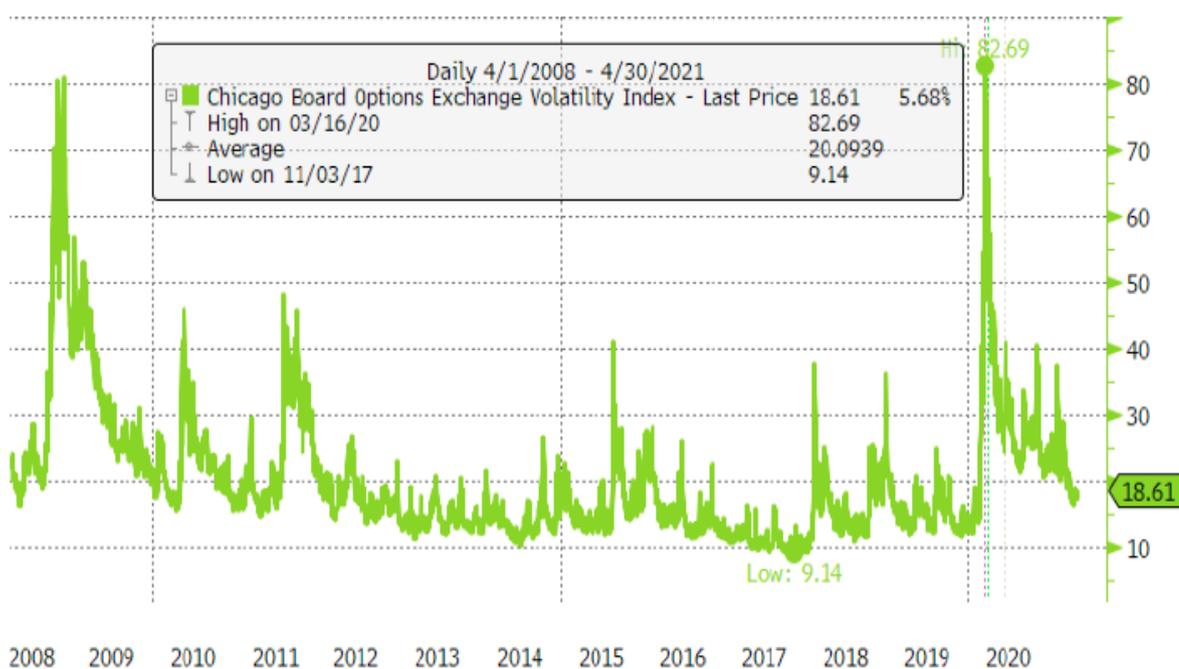
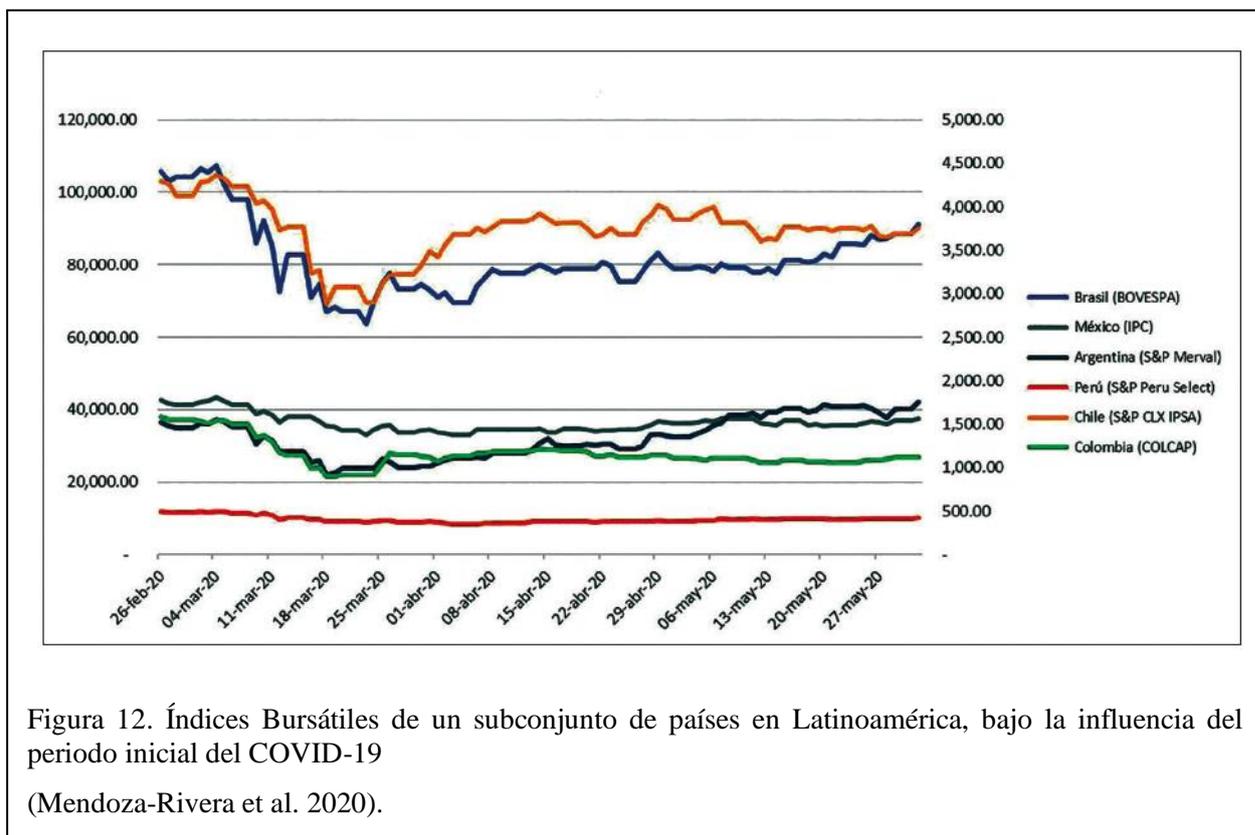


Figura 13. Índice de Volatilidad de Mercados (VIX)

(Bloomberg Finance L.P. 2021.)

Los resultados mostrados para esta muestra de países de Latinoamérica, así como los obtenidos mediante este estudio para la Bolsa de Valores de Quito, son también consistentes con el Índice de Volatilidad CBOE (VIX) (ver figura 13), que muestra un valor de 82,69 para febrero de 2020; valor únicamente comparable con los niveles alcanzados durante la crisis del 2008.

A pesar las evidencias mostradas en este trabajo, sobre el impacto negativo generado por el COVID-19 en los mercados de valores internacionales y nacional; los resultados obtenidos para la recuperación de precios mediante en algoritmo BFAST confirman que los efectos ocasionados por el COVID-19 en la Bolsa de Valores de Quito son de corta duración y el proceso de recuperación tuvo lugar a partir de enero de 2021. Estos resultados concuerdan con las conclusiones alcanzadas por He et al. (2020). En este trabajo, los autores analizan la recuperación de los mercados de valores de los 8 países (República de China, Italia, Corea del Sur, Francia, España, Alemania, Japón y Estados Unidos), y concluyen que para finales de 2020 los mercados de valores de los 8 países mostraban indicios de recuperación.

En referencia a los quiebres estructurales detectados por BFAST, es importante mencionar que para el sector financiero, CUSUM no detectó los quiebres estructurales para Produbanco ni para la Bolsa de Valores de Quito, ambos asociados con el periodo COVID. De igual modo, CUSUM no detectó los quiebres de recuperación para ninguna de estas dos empresas. Respecto al sector comercial y productivo, CUSUM no detectó el quiebre estructural en periodo COVID de Holcim, y no detectó la recuperación en periodo POST-COVID ni para la Cervecería Nacional ni para Holcim. Estos resultados permiten deducir una superioridad significativa de BFAST para la detección de quiebres estructurales asociados a cambios de tendencia, en comparación con CUSUM.

Los quiebres estructurales negativos obtenidos por BFAST durante la fase COVID, fueron definidos en el mes de marzo para Produbanco y para la Bolsa de Valores de Quito, para agosto de 2020 para Cervecería Nacional, y en diciembre de 2020 para Holcim. Los resultados obtenidos en las empresas del sector financiero por BFAST, son consistentes con los resultados de quiebres estructurales obtenidos por [Chang y Li \(2022\)](#). Los autores reportaron un quiebre estructural en marzo de 2020 para el coeficiente de correlación de Kendall para futuros de petróleo y mercado de valores NDQA de los Estados Unidos (ver figura 14).

También, en la figura 14 se muestra que se detecta un quiebre de recuperación para junio de 2020. Si bien, este resultado responde a realidades intrínsecas de los Estados

Unidos, es importante resaltar que el quiebre de caída coincide con el mes de detección para Ecuador. Mientras que hay un desfase, entre los quiebres detectados en el sector comercial y productivo, y las fechas de los quiebres de recuperación, lo cual es natural por las diferencias entre ambos mercados. Para realizar la detección de quiebre, los autores utilizaron el modelo ARMA-GARCH, en conjunto con el modelo R-vine copula. Lo que les permitió detectar quiebres estructurales, considerando la correlación entre futuros de petróleo y mercado de valores NDQA

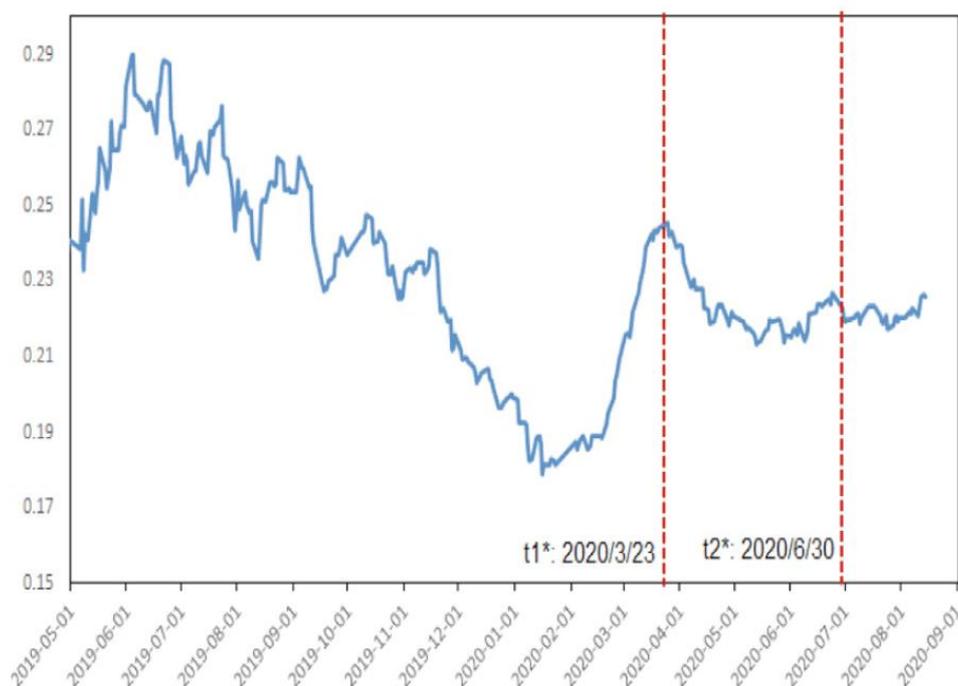


Figura 14. Quiebres estructurales detectados en el coeficiente de correlación de Kendall para futuros de petróleo y mercado de valores NDQA de los Estados Unidos.

La relevancia de los resultados obtenidos mediante este trabajo, también ha sido analizada en el contexto nacional. Si bien, en la literatura especializada actual se identifican análisis el impacto del COVID-19 en diferente aspectos de la vida nacional, este análisis estuvo enfocado en identificar trabajos en el sector financiero y mediante detección de quiebres estructurales, para garantizar criterios comparativos.

En este contacto, [Alarcón y Maldonado \(2021\)](#) realizaron un análisis de quiebres estructurales para analizar el impacto del COVID-19 en las instituciones de economía

popular y solidaria del Ecuador. Para la detección de quiebres estructurales, los autores aplicaron modelos ARMA para la morosidad, colocaciones, depósitos, entre otras variables, y realizaron la detección de quiebres estructurales mediante el Test de Chow.

Los autores realizaron los análisis considerando el periodo PRE-COVID (2019), el periodo COVID (2020), y periodo POST-COVID (2021). En referencia al impacto, se obtuvieron resultados muy relevantes. Por ejemplo, el test de Chow mostró significancia estadística para la detección de quiebres de las series de morosidad, colocaciones de los sectores comerciales y de vivienda, captaciones y de clientes, para marzo de 2020, utilizando como caso de estudio a las 522 instituciones que al momento de la investigación conformaban el Sector Financiero Popular y Solidario del Ecuador.

Los resultados reportados por [Alarcón y Maldonado \(2021\)](#), validan la tendencia de los resultados de quiebres estructurales obtenidos mediante este trabajo para marzo de 2020. También, son consistentes con los resultados reportados por los autores anteriormente referenciados, en cuanto al impacto observado en el mercado de valores internacional. En el siguiente capítulo, se proporcionan las principales conclusiones alcanzadas en este trabajo.

Conclusiones y recomendaciones

Conclusiones

En este trabajo, se realizó una actualización sistemática sobre el estado del arte en el uso de enfoques y tendencias metodológicas para la caracterización de impactos en riesgo de mercado debido a la pandemia COVID-19 en el ámbito de mercado de valores. Con base a esta revisión bibliográfica, se detectó la oportunidad de implementar técnicas de detección de quiebres estructurales durante el periodo que inicia en enero de 2019 y finaliza en diciembre de 2022, en una muestra de 10 empresas que cotizan en la Bolsa de Valores de Quito, para explorar si los efectos del COVID-19 generaron efectos suficientemente importantes como para generar quiebres estructurales en los precios de cotización de acciones del mercado de valores nacional.

Como una propuesta innovadora, se diseñó un modelo metodológico para realizar la detección de quiebres estructurales mediante el algoritmo BFAST. Este algoritmo incluye una mejora del algoritmo CUSUM, que ha sido tradicionalmente utilizado para la detección de quiebres estructurales en mercados financieros por más de cinco décadas.

De acuerdo con la literatura especializada, BFAST ha sido utilizado de manera exitosa en la detección de quiebres estructurales en series temporales derivadas de índices de imágenes satelitales, para aplicaciones de observación de la superficie de la tierra y en este trabajo de investigación, fue probado para evaluar su potencialidad en aplicaciones en el área de finanzas.

Con el objetivo de comparar los resultados proporcionados por BFAST se tomó como referencia al algoritmo CUSUM dado los antecedentes de estudios similares.

Las primeras fases del diseño metodológico implicaron la recolección de datos desde la Bolsa de Valores de Quito, el pre-procesamiento de los datos y la selección de las 10 empresas más relevantes. Los datos son proporcionados en un formato general y de tipo anual, que requirió realizar etapas de filtrado e interpolación para disponer de los datos en un formato que facilitara su ingreso a los algoritmos BFAST y CUSUM.

Posteriormente se realizó la detección de quiebres estructurales mediante los algoritmos BFAST y CUSUM. Para la detección de quiebre se definieron los siguientes periodos de interés: i) para la etapa PRE-COVID, definida entre enero y diciembre de 2019, ii) para la etapa COVID, comprendida entre enero y diciembre de 2020, y iii) para la etapa POST-COVID, definido entre enero de 2021 y diciembre de 2022. Esta

segmentación temporal, fue idónea en el afán de identificar la época en la que se detectan los quiebres estructurales, y evaluar las tendencias de los precios de cotización para cada periodo determinado por la pandemia del COVID-19.

El análisis comparativo entre los algoritmos BFAST y Strucchange, demostró una mayor capacidad por parte de BFAST para detectar quiebres estructurales asociados a cambios de tendencias en el precio de cotización de las acciones. Este resultado es de mucha importancia, en el contexto de que los quiebres estructurales detectados y que están vinculados a cambios de tendencia, pueden ser utilizados con fines predictivos. Esta propiedad de BFAST, tiene su origen en el hecho de que BFAST mejora a CUSUM en el peso que les proporciona a los cambios en el componente de tendencia en el proceso de detección de quiebres estructurales.

BFAST mostró mayor capacidad que CUSUM para generar quiebres asociados con cambios de tendencias relativos. Este es un punto fuerte de BFAST, ya que esta característica permite identificar de un modo más preciso la dinámica de las series temporales, en referencia a los cambios de precios locales en las cotizaciones de las acciones. Cuando no hay cambios de tendencia absolutos BFAST detecta menos quiebres en comparación con CUSUM.

CUSUM detecta quiebres aun cuando no están relacionados con cambios de tendencia. BFAST puede detectar quiebres sin cambio de tendencia, cuando se profundiza la tendencia. Por ejemplo, BFAST detectó quiebre para la serie temporal de Cervecería Nacional en la fase POST-COVID aun cuando no hubo cambio de tendencia, debido a que se profundizó la tendencia en la serie temporal. Este caso difiere de la serie temporal de Corporación Favorita, en donde CUSUM detectó un quiebre estructural negativo, mientras que BFAST no.

El análisis comparativo demostró que, si bien hay diversas coincidencias en fechas y condiciones en las que CUSUM y BFAST detectan los quiebres estructurales, los quiebres estructurales detectados por BFAST, proporcionan más información para la toma de decisiones, al estar vinculados generalmente a cambios de tendencia.

La detección de los quiebres estructurales, aunado con los perfiles de las series temporales, permitieron analizar y valorar, la existencia o no, de efectos ocasionados por la pandemia del COVID-19. En el sector financiero, durante la fase de COVID-19, las 5 empresas experimentaron bajas significativas en el precio de cotización de sus acciones. A excepción del Banco Pichincha, todas las empresas recuperaron sus precios de cotización durante la etapa POST-COVID.

El algoritmo CUSUM no detectó quiebres estructurales asociados a estas caídas de precio. BFAST detectó quiebres estructurales asociados a cambios de tendencias de pérdidas para Produbanco y para la Bolsa de Valores de Quito. En referencia a quiebres de recuperación en la fase POST-COVID, CUSUM detectó quiebres de recuperación para Banco Guayaquil, Mutualista Pichincha y Bolsa de Valores de Quito. Similarmente, BFAST detectó quiebres de recuperación para las mismas empresas que CUSUM. Es importante resaltar que, aunque BFAST detectó quiebres para las mismas empresas, las localizaciones de los quiebres de BFAST para Produbanco y la Bolsa de Valores de Quito, describen en mejor forma la dinámica de cambios en la tendencia.

Para el sector productivo y comercial, los eventos vinculados al COVID-19 muestran aspectos más negativos. Cervecería Nacional, Holcim, Industrias Ales y Corporación Favorita experimentaron caídas suaves en los precios de sus acciones, mientras que San Carlos mantuvo su precio de cotización constante. En la fase POST-COVID, las caídas fueron significativamente fuertes para Cervecería Nacional, Holcim, y Corporación Favorita. Para Industrias Ales y San Carlos, las caídas fueron más suaves.

CUSUM detectó quiebres estructurales de baja en la fase COVID para Industrias Ales, Corporación Favorita, y Cervecería Nacional. En el periodo POST-COVID, CUSUM detectó quiebres de baja para Cervecería Nacional y Holcim. Sin embargo, CUSUM no detectó quiebres estructurales asociados a recuperación, aun cuando se observó recuperación al final de la fase POST-COVID para Holcim, Industrias Ales y San Carlos.

BFAST detectó quiebre estructural de caída para la fase COVID, en Cervecería Nacional y Holcim. El análisis permite deducir, que BFAST no detectó quiebres para las otras 3 empresas, debido a que no hubo cambio de tendencia. Esto significa, que las empresas venían con tendencia de baja, desde la fase de PRE-COVID. Para la fase POST-COVID, BFAST detectó quiebres estructurales de recuperación para las empresas Holcim, Industrias Ales y San Carlos. También, BFAST detectó profundización de caída para Cervecería Nacional. Es interesante resaltar que, para Corporación Favorita, BFAST no detectó quiebre, porque esta empresa tuvo una tendencia demarcada a la caída durante todo el periodo de estudio.

Estos resultados permiten deducir, que BFAST tiene una alta potencialidad para la detección de quiebres estructurales en series temporales de mercado de valores. Si bien, para este estudio se utilizó para identificar efectos ocasionados por la pandemia COVID-19, estos resultados podrían extrapolarse a detectar momentos adecuados para compra y

venta de acciones en el mercado de valores. Finalmente, en la implementación de BFAST en los casos de estudio, se evidenció que la mejora realizada al algoritmo, en referencia a la metodología CUSUM, permite caracterizar de un modo más apropiados los cambios de tendencias en las series temporales.

Recomendaciones

Los resultados obtenidos en este estudio han identificado oportunidades de implementar algoritmos BFAST con fines predictivos. Por este motivo, en futuras investigaciones, se podría explorar la potencialidad de usar BFAST para detectar quiebres estructurales a tiempo real, que permitan guiar la toma de decisiones sobre compra y venta de acciones con la finalidad de optimizar niveles de rendimientos.

De igual modo, este estudio contempló el periodo de análisis durante los años 2019 a 2022. Por lo que estudio posteriores podrían centrarse en el periodo 2023 y 2024 para evaluar si las tendencias identificadas en este estudio se mantuvieron o cambiaron en los años posteriores.

Obras citadas

- Alarcón, Gema Viviana Paula, y Juan Carlos Olives Maldonado. 2022. “Impacto financiero del COVID 19 en las instituciones de economía popular y solidaria del Ecuador, año 2021”. *Visionario digital* 6 (3): 97–122.
- Alzúa, María Laura, y Paula Gosis. 2020. “Impacto Social y Económico de la COVID-19 y Opciones de Políticas en Argentina”. *PNUD América Latina y el Caribe* 6: 1–27.
- Andrews, Donald W. K. 1993. “Tests for Parameter Instability and Structural Change With Unknown Change Point”. *Econometrica* 61 (4). [Wiley, Econometric Society]: 821–56. doi:10.2307/2951764.
- Andrews, Donald W. K., y Werner Ploberger. 1994. “Optimal Tests when a Nuisance Parameter is Present Only Under the Alternative”. *Econometrica* 62 (6). [Wiley, Econometric Society]: 1383–1414. doi:10.2307/2951753.
- Apergis, Nicholas, Matteo Bonato, Rangan Gupta, y Clement Kyei. 2017. “Does Geopolitical Risks Predict Stock Returns and Volatility of Leading Defense Companies? Evidence from a Nonparametric Approach”. *Defence and Peace Economics*, febrero, 1–13. doi:10.1080/10242694.2017.1292097.
- Ayittey, Foster K., Matthew K. Ayittey, Nyasha B. Chiwero, Japhet S. Kamasah, y Christian Dzuvoor. 2020. “Economic impacts of Wuhan 2019-nCoV on China and the world”. *Journal of medical virology* 92 (5). Wiley-Blackwell: 473.
- Bai, Jushan, y Pierre Perron. 2003. “Computation and Analysis of Multiple Structural Change Models”. *Journal of Applied Econometrics* 18 (1): 1–22. doi:10.1002/jae.659.
- Baker, Scott, Nicholas Bloom, Steven Davis, Kyle Kost, Marco Sammon, y Tasaneeya Viratyosin. 2020. “The Unprecedented Stock Market Impact of COVID-19”. w26945. Cambridge, MA: National Bureau of Economic Research. doi:10.3386/w26945.
- Bernanke, Ben S., y Kenneth N. Kuttner. 2003. “What Explains the Stock Market’s Reaction to Federal Reserve Policy?” *SSRN Electronic Journal*, 1–57. doi:10.2139/ssrn.890610.
- Binder, John, y Matthias Merges. 2001. “Stock market volatility and economic factors”. *Review of Quantitative Finance and Accounting*.
- Boissay, F., y Phurichai Rungcharoenkitkul. 2020. “Macroeconomic effects of Covid-19: an early review”. En . <https://www.semanticscholar.org/paper/Macroeconomic-effects-of-Covid-19%3A-an-early-review-Boissay-Rungcharoenkitkul/80cb0dd810ffa0d604efda75f3de1152912368d2>.
- Bouras, Christos, Christina Christou, Rangan Gupta, y Tahir Suleman. 2019. “Geopolitical Risks, Returns, and Volatility in Emerging Stock Markets: Evidence from a Panel GARCH Model”. *Emerging Markets Finance and Trade* 55 (8): 1841–56. doi:10.1080/1540496X.2018.1507906.

- Bouri, Elie, Riza Demirer, Rangan Gupta, y Hardik A. Marfatia. 2019. “Geopolitical Risks and Movements in Islamic Bond and Equity Markets: A Note”. *Defence and Peace Economics* 30 (3): 367–79. doi:10.1080/10242694.2018.1424613.
- Brown, R. L., J. Durbin, y J. M. Evans. 1975. “Techniques for Testing the Constancy of Regression Relationships Over Time”. *Journal of the Royal Statistical Society: Series B (Methodological)* 37 (2): 149–63. doi:10.1111/j.2517-6161.1975.tb01532.x.
- Cadena, Javier, Henry Pinargote, y Karen Solorzano. 2018. “Mercado de valores y su contribución al crecimiento de la economía ecuatoriana”. *Revista Venezolana de Gerencia* 23: 562–74.
- Ceballos-Palma, Katherine, Katina Bermeo-Pazmiño, y Lenyn Vásquez-Acuña. 2020. “Covid-19 y su impacto contable en las PYMES del cantón Cuenca”. *Revista Arbitrada Interdisciplinaria Koinonía* 5 (4). Fundación Koinonía: 273–98.
- CEPAL, NU. 2020. “Estudio Económico de América Latina y el Caribe”. <https://repositorio.cepal.org/server/api/core/bitstreams/ba9a5855-fbdf-4643-ae1b-d04b7475c18d/content>.
- Chan, Wesley S. 2001. “Stock Price Reaction to News and No-News: Drift and Reversal After Headlines”. *SSRN Electronic Journal*. doi:10.2139/ssrn.262452.
- Chang, Kai, y Sheng Ze Li. 2022. “Does COVID-19 pandemic event alter the dependence structure breaks between crude oil and stock markets in Europe and America”. *Energy Reports* 8 (noviembre): 15106–23. doi:10.1016/j.egyr.2022.10.450.
- Chatzikonstanti, Vasiliki. 2017. “Breaks and Outliers When Modelling the Volatility of the U.S. Stock Market”. *Applied Economics* 49 (46): 4704–17. doi:10.1080/00036846.2017.1293785.
- Chen, Shiu-Sheng. 2007. “Does Monetary Policy Have Asymmetric Effects on Stock Returns?” *Journal of Money, Credit and Banking* 39 (2/3). [Wiley, Ohio State University Press]: 667–88.
- Chia-Shang, J. Chu, Kurt Hornik, y Kaun Chung-Ming. 1995. “MOSUM tests for parameter constancy”. *Biometrika* 82 (3): 603–17. doi:10.1093/biomet/82.3.603.
- Conrad, Christian, y Karin Loch. 2012. “Anticipating Long-Term Stock Market Volatility”, 1–54.
- De los Baños, María, y José Roldán-Casas. 2021. “Análisis del grado de eficiencia débil en algunos mercados financieros europeos. Primer impacto del COVID-19”. *Revista de economía mundial*, n° 59: 243–69. doi:http://dx.doi.org/10.33776/rem.v0i59.5157.
- Dominicy, Yves, y Harry Vander. 2015. “Macro-Driven VAR Forecasts: From Very High to Very Low-Frequency Data”. *SSRN Electronic Journal*. doi:10.2139/ssrn.2701256.
- EC, BCE. 2019. “Bolsa de valores de quito reporte diario 30-dic-2019”. Quito: BCE. <https://www.bce.fin.ec/index.php/component/k2/item/281-bolsa-de-valores-de-quito>.
- EC, BVQ. 2019. “Informe bursátil mensual sobre las negociaciones a nivel nacional”. Quito: BVQ.

- . 2022. “Informe bursátil mensual sobre las negociaciones a nivel nacional”. <https://www.bolsadequito.com/index.php/estadisticas/boletines/boletines-mensuales>.
- EC, Ministerio de Producción Comercio Exterior Inversiones y Pesca. 2020. “Comunicado sobre la circulación de vehículos, transporte de personas y mercancías – Ministerio de Producción Comercio Exterior Inversiones y Pesca”. marzo 17. <https://www.produccion.gob.ec/comunicado-sobre-la-circulacion-de-vehiculos-transporte-de-personas-y-mercancias/>.
- EC, Secretaría General de Comunicación de la Presidencia. 2020. “Se registra el primer caso de coronavirus en Ecuador – Secretaría General de Comunicación de la Presidencia”. <https://www.comunicacion.gob.ec/se-registra-el-primer-caso-de-coronavirus-en-ecuador/>.
- Engle, Robert F., Eric Ghysels, y Bumjean Sohn. 2013. “Stock Market Volatility and Macroeconomic Fundamentals”. *The Review of Economics and Statistics* 95 (3). The MIT Press: 776–97.
- Fernandes, Nuno. 2020. “Economic Effects of Coronavirus Outbreak (COVID-19) on the World Economy”. SSRN Scholarly Paper. Rochester, NY. doi:10.2139/ssrn.3557504.
- Fullana, Olga, Javier Ruiz, y David Toscano. 2021. “Stock Market Bubbles and Monetary Policy Effectiveness”. *The European Journal of Finance* 27 (10): 963–75. doi:10.1080/1351847X.2020.1782960.
- Gao, Yan, Jonathan V. Solórzano, Alexander Quevedo, y Jaime Octavio Loya-Carrillo. 2021. “How BFAST Trend and Seasonal Model Components Affect Disturbance Detection in Tropical Dry Forest and Temperate Forest”. *Remote Sensing* 13 (11). Multidisciplinary Digital Publishing Institute: 2033. doi:10.3390/rs13112033.
- Gkillas, Konstantinos, Rangan Gupta, y Mark E. Wohar. 2018. “Volatility Jumps: The Role of Geopolitical Risks”. *Finance Research Letters* 27 (diciembre): 247–58. doi:10.1016/j.frl.2018.03.014.
- Grogan, Kenneth, Dirk Pflugmacher, Patrick Hostert, Jan Verbesselt, y Rasmus Fensholt. 2016. “Mapping Clearances in Tropical Dry Forests Using Breakpoints, Trend, and Seasonal Components from MODIS Time Series: Does Forest Type Matter?” *Remote Sensing* 8 (8): 1–27. doi:10.3390/rs8080657.
- Haywood, John, y John Randal. 2008. “Trending seasonal data with multiple structural breaks. NZ visitor arrivals and the minimal effects of 9/11”, marzo.
- He, Qing, Junyi Liu, Sizhu Wang, y Jishuang Yu. 2020. “The Impact of COVID-19 on Stock Markets”. *Economic and Political Studies* 8 (3): 275–88. doi:10.1080/20954816.2020.1757570.
- Henry, Ólan T. 2009. “Regime Switching in the Relationship between Equity Returns and Short-Term Interest Rates in the UK”. *Journal of Banking & Finance* 33 (2): 405–14. doi:10.1016/j.jbankfin.2008.08.001.
- Honda, Yuzo, y Yoshihiro Kuroki. 2006. “Financial and Capital Markets’ Responses to Changes in the Central Bank’s Target Interest Rate: The Case of Japan”. *The Economic Journal* 116 (513). [Royal Economic Society, Wiley]: 812–42.
- Huamán, Jackeline Roxana. 2021. “Impacto económico y social de la COVID-19 en el Perú”. *Revista de Ciencia e Investigación en Defensa-CAEN* 2 (1): 31–42.

- Huilcapi, Nora, Katherine Troya, y Wendy Ocampo. 2020. "Impacto del COVID-19 en la planeación estratégica de las pymes ecuatorianas". *Recimundo* 4 (3): 76–85.
- Idrees, Sheikh Mohammad, M. Afshar Alam, y Parul Agarwal. 2019. "A Prediction Approach for Stock Market Volatility Based on Time Series Data". *IEEE Access* 7: 17287–98. doi:10.1109/ACCESS.2019.2895252.
- Jumbo, Diana, John Campuzano, Flor Vega, y Ángel Luna. 2020. "Crisis económicas y covid-19 en ecuador: impacto en las exportaciones".
- Kamal, Md Rajib, Mohammad Ferdous, y Md Hosain. 2022. "Stock market reactions of maritime shipping industry in the time of COVID-19 pandemic crisis: an empirical investigation". *Maritime Policy & Management* 49 (8). Taylor & Francis: 1184–99.
- Katafuchi, Yuya, Kenichi Kurita, y Shunsuke Managi. 2020. "COVID-19 with stigma: Theory and evidence from mobility data". *Economics of Disasters and Climate Change* 5. Springer: 71–95.
- Kontonikas, Alexandros, Ronald MacDonald, y Aman Saggi. 2013. "Stock Market Reaction to Fed Funds Rate Surprises: State Dependence and the Financial Crisis". *Journal of Banking & Finance* 37 (11): 4025–37. doi:10.1016/j.jbankfin.2013.06.010.
- Kuan, Chung-Ming, y Kurt Hornik. 1995. "The generalized fluctuation test: A unifying view". *Econometric Reviews* 14 (2). Taylor & Francis: 135–61. doi:10.1080/07474939508800311.
- Kurita, Kenichi, y Shunsuke Managi. 2022. "COVID-19 and stigma: Evolution of self-restraint behavior". *Dynamic Games and Applications* 12 (1). Springer: 168–82.
- Kurov, Alexander. 2010. "Investor Sentiment and the Stock Market's Reaction to Monetary Policy". *Journal of Banking & Finance* 34 (1): 139–49. doi:10.1016/j.jbankfin.2009.07.010.
- Lee, Hee. 2020. "Exploring the initial impact of COVID-19 sentiment on US stock market using big data". *Sustainability* 12 (16). MDPI: 6648.
- Li, Weiqing, Fengsheng Chien, Hafiz Kamran, Talla M. Aldeehani, Muhammad Sadiq, Van Nguyen, y Farhad Taghizadeh-Hesary. 2022. "The nexus between COVID-19 fear and stock market volatility". *Economic research-Ekonomska istraživanja* 35 (1). Taylor & Francis: 1765–85.
- Maya Chávez, Shirley Katherine. 2022. "Impacto financiero del covid19 en empresas que cotizan en la bolsa de valores". Guayaquil: Politécnica Salesiana Ecuador.
- McQueen, Grant, y V. Vance Roley. 1993. "Stock Prices, News, and Business Conditions". *Review of Financial Studies* 6 (3): 683–707. doi:10.1093/rfs/5.3.683.
- Mendoza-Rivera, Ricardo J., José Antonio Lozano-Díez, y Francisco Venegas-Martínez. 2020. "Impacto de la pandemia Covid-19 en variables financieras relevantes en las principales economías de Latinoamérica". *Economía: teoría y práctica*, n° SPE5. Universidad Autónoma Metropolitana, a través de la Unidad Iztapalapa, la Unidad Azcapotzalco y la Unidad Xochimilco, División de Ciencias Sociales: 125–44. doi:10.24275/etypuam/ne/e052020/mendoza.

- Muñoz, Erith, Alfonso Zozaya, y Erik Lindquist. 2020. "Satellite remote sensing of forest degradation using NDFI and the BFAST algorithm". *IEEE Latin America Transactions* 18 (07). IEEE: 1288–95.
- Nguyen, Tho, y Chau Ngo. 2014. "Impacts of the US Macroeconomic News on Asian Stock Markets". *The Journal of Risk Finance* 15 (2): 149–79. doi:10.1108/JRF-09-2013-0064.
- Niederhoffer, Victor. 1971. "The Analysis of World Events and Stock Prices". *The Journal of Business* 44 (2). University of Chicago Press: 193–219.
- OMS. 2020a. "Nuevo coronavirus 2019". <https://www.who.int/es/emergencias/diseases/novel-coronavirus-2019>.
- OMS, OPS. 2020b. "La OMS caracteriza a COVID-19 como una pandemia - OPS/OMS | Organización Panamericana de la Salud". marzo 11. <https://www.paho.org/es/noticias/11-3-2020-oms-caracteriza-covid-19-como-pandemia>.
- Ponnam, Lakshmi, V. Srinivasa, K. Srinivas, y Vamsi Raavi. 2016. "A comparative study on techniques used for prediction of stock market". En *2016 International Conference on Automatic Control and Dynamic Optimization Techniques (ICACDOT)*, 1–6. International Institute of Information Technology. doi:10.1109/ICACDOT.2016.7877541.
- Rapach, David E., y Jack K. Strauss. 2008. "Structural Breaks and GARCH Models of Exchange Rate Volatility". *Journal of Applied Econometrics* 23 (1): 65–90. doi:10.1002/jae.976.
- Rapach, David, Jack Strauss, y Mark Wohar. 2008. "Chapter 10 Forecasting Stock Return Volatility in the Presence of Structural Breaks". En , 3:381–416. Elsevier. doi:10.1016/S1574-8715(07)00210-2.
- Reiche, Johannes, Sytze de Bruin, Dirk Hoekman, Jan Verbesselt, y Martin Herold. 2015. "A Bayesian Approach to Combine Landsat and ALOS PALSAR Time Series for Near Real-Time Deforestation Detection". *Remote Sensing* 7 (5): 4973–96. doi:10.3390/rs70504973.
- Ruiz, Mario, Donghyun Park, Evangelos Koutronas, Alam Khan, y Muhammad Tahir. 2020. "The impact of infectious and contagious diseases and its impact on the economic performance: The case of Wuhan, China". *China (January 29, 2020)*.
- Sánchez Gabarre, Mary Elena. 2020. "Stock prices, uncertainty and risks: Evidence from developing and advanced economies". *European Journal of Government and Economics* 9 (3): 265–79. doi:10.17979/ejge.2020.9.3.6999.
- Sánchez, Paola. 2008. "Cambios estructurales en series de tiempo: una revisión del estado del arte", abril, 115–40.
- Santa-Clara, Pedro, y Rossen Valkanov. 2003. "The Presidential Puzzle: Political Cycles and the Stock Market". *The Journal of Finance* 58 (5): 1841–72. doi:10.1111/1540-6261.00590.
- Savor, Pavel G. 2011. "Stock Returns after Major Price Shocks: The Impact of Information". *SSRN Electronic Journal*. doi:10.2139/ssrn.1306233.

- Schneider, Gerald, y Vera E. Troeger. 2006. “War and the World Economy: Stock Market Reactions to International Conflicts”. *Journal of Conflict Resolution* 50 (5): 623–45. doi:10.1177/0022002706290430.
- Schultz, Michael, Jan Verbesselt, Valerio Avitabile, Carlos Souza, y Martin Herold. 2016. “Error Sources in Deforestation Detection Using BFAST Monitor on Landsat Time Series Across Three Tropical Sites”. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9 (8): 3667–79. doi:10.1109/JSTARS.2015.2477473.
- Sharma, Gagan Deep, Mandeep Mahendru, y Mrinalini Srivastava. 2019. “Can Central Banking Policies Make a Difference in Financial Market Performance in Emerging Economies? The Case of India”. *Economies* 7 (2): 1–19. doi:10.3390/economies7020049.
- Venables, W. N., y B. D. Ripley. 2013. *Modern Applied Statistics with S-PLUS*. Springer Science & Business Media. <http://www.jstor.org/stable/2532871> .
- Verbesselt, Jan, Rob Hyndman, Glenn Newnham, y Darius Culvenor. 2010. “Detecting Trend and Seasonal Changes in Satellite Image Time Series”. *Remote Sensing of Environment* 114 (1): 106–15. doi:10.1016/j.rse.2009.08.014.
- Verbesselt, Jan, Rob Hyndman, Achim Zeileis, y Darius Culvenor. 2010. “Phenological Change Detection While Accounting for Abrupt and Gradual Trends in Satellite Image Time Series”. *Remote Sensing of Environment* 114 (12): 2970–80. doi:10.1016/j.rse.2010.08.003.
- Verma, Parag, Ankur Dumka, Anuj Bhardwaj, Alaknanda Ashok, Mukesh Chandra Kestwal, y Praveen Kumar. 2021. “A Statistical Analysis of Impact of COVID19 on the Global Economy and Stock Index Returns”. *SN Computer Science* 2 (1): 27. doi:10.1007/s42979-020-00410-w.
- Xin, Lv. 2014. “Asymmetric Effects of Monetary Policy Shocks on Stock Markets : An Empirical Test for China”. *En* , 1–19. <https://www.semanticscholar.org/paper/Asymmetric-Effects-of-Monetary-Policy-Shocks-on-%3A-Xin/c3c47dc09953822a5efc699cb0f4408d38b7140d>.
- Xu, Ke-Li. 2013. “Powerful Tests for Structural Changes in Volatility”. *Journal of Econometrics* 173 (1): 126–42. doi:10.1016/j.jeconom.2012.11.001.
- Yoo, Sunbin, y Shunsuke Managi. 2020. “Global mortality benefits of COVID-19 action”. *Technological Forecasting and Social Change* 160. Elsevier: 120231.
- Yousfi, Mohamed, Younes Ben Zaied, Nidhaleddine Ben Cheikh, Béchir Ben Lahouel, y Houssein Bouzgarrou. 2021. “Effects of the COVID-19 Pandemic on the US Stock Market and Uncertainty: A Comparative Assessment between the First and Second Waves”. *Technological Forecasting and Social Change* 167 (junio): 1–13. doi:10.1016/j.techfore.2021.120710.
- Yücel, Hikmet. 2020. “Effect of Representation of Information in the Input of Deep Learning on Prediction Success”. En *Artificial Intelligence and Applied Mathematics in Engineering Problems*, editado por D. Jude Hemanth y Utku Kose, 709–23. Lecture Notes on Data Engineering and Communications Technologies. Cham: Springer International Publishing. doi:10.1007/978-3-030-36178-5_60.

- Zeileis, Achim, Christian Kleiber, Walter Krämer, y Kurt Hornik. 2003. “Testing and Dating of Structural Changes in Practice”. *Computational Statistics & Data Analysis*, Special Issue in Honour of Stan Azen: a Birthday Celebration, 44 (1): 109–23. doi:10.1016/S0167-9473(03)00030-6.
- Zhu, Zhe, y Curtis E. Woodcock. 2014. “Continuous Change Detection and Classification of Land Cover Using All Available Landsat Data”. *Remote Sensing of Environment* 144 (marzo): 152–71. doi:10.1016/j.rse.2014.01.011.

Anexos

Anexo 1: Script main.py

```

#%%
# importacion de librerias
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np
import xlrd

#%%
# Lectura de datos para 2013
data2013 = pd.read_excel('./Datos/2013-2016.xls', sheet_name='2013')
print(data2013.head(10))
print(data2013.columns)
data2013.drop(data2013[data2013['PROCEDENCIA'] == 'G'].index, inplace=True)
data2013 = data2013[["FECHA", "EMISOR", "PRECIO"]]
print(data2013.columns)
print('Numero de companias cotizando en 2013:', data2013['EMISOR'].nunique())
print('Numero de cotizaciones por companias en 2013: ', data2013['EMISOR'].value_counts())
data2013 = data2013[~data2013['EMISOR'].isin(data2013['EMISOR'].value_counts()
                                          .it(12).pipe(lambda s: s[s.index]))]
data2013['FECHA']=data2013['FECHA'].apply(pd.to_datetime, errors='coerce').dropna()
data2013mean=data2013.groupby([pd.PeriodIndex(data2013['FECHA'], freq="M"),
                              'EMISOR'])['PRECIO'].median().reset_index()
print(data2013mean.columns)
print('Dimensiones de los datos de 2013:', data2013mean.shape)
print('Numero de cotizaciones mensuales por companias en 2013: ',
      data2013mean['EMISOR'].value_counts())
#%%
# Lectura de datos para 2014
data2014 = pd.read_excel('./Datos/2013-2016.xls', sheet_name='2014')
print(data2014.head(10))
print(data2014.columns)
data2014.drop(data2014[data2014['PROCEDENCIA'] == 'G'].index, inplace=True)
data2014 = data2014[["FECHA", "EMISOR", "PRECIO"]]

```

```

print(data2014.columns)
print('Numero de companias cotizando en 2014:', data2014['EMISOR'].nunique())
print('Numero de cotizaciones por companias en 2014: ', data2014['EMISOR'].value_counts())
data2014 = data2014[~data2014['EMISOR'].isin(data2014['EMISOR'].value_counts()
                                     .it(12).pipe(lambda s: s[s.index])]
data2014['FECHA']=data2014['FECHA'].apply(pd.to_datetime, errors='coerce').dropna()
data2014mean=data2014.groupby([pd.PeriodIndex(data2014['FECHA'], freq="M"),
                              'EMISOR'])['PRECIO'].median().reset_index()
print(data2014mean.columns)
print('Dimensiones de los datos de 2014:', data2014mean.shape)
print('Numero de cotizaciones mensuales por companias en 2014: ',
      data2014mean['EMISOR'].value_counts())
#%%
# Lectura de datos para 2015
data2015 = pd.read_excel('./Datos/2013-2016.xls', sheet_name='2015')
print(data2015.head(10))
print(data2015.columns)
data2015.drop(data2015[data2015['PROCEDENCIA'] == 'G'].index, inplace=True)
data2015 = data2015[["FECHA", "EMISOR", "PRECIO"]]
print(data2015.columns)
print('Numero de companias cotizando en 2015:', data2015['EMISOR'].nunique())
print('Numero de cotizaciones por companias en 2015: ', data2015['EMISOR'].value_counts())
data2015 = data2015[~data2015['EMISOR'].isin(data2015['EMISOR'].value_counts()
                                     .it(12).pipe(lambda s: s[s.index])]
data2015['FECHA']=data2015['FECHA'].apply(pd.to_datetime, errors='coerce').dropna()
data2015mean=data2015.groupby([pd.PeriodIndex(data2015['FECHA'], freq="M"),
                              'EMISOR'])['PRECIO'].median().reset_index()
print(data2015mean.columns)
print('Dimensiones de los datos de 2015:', data2015mean.shape)
print('Numero de cotizaciones mensuales por companias en 2015: ',
      data2015mean['EMISOR'].value_counts())
#%%
# Lectura de datos para 2016
data2016 = pd.read_excel('./Datos/2013-2016.xls', sheet_name='2016')
print(data2016.head(10))
print(data2016.columns)
data2016.drop(data2016[data2016['PROCEDENCIA'] == 'G'].index, inplace=True)
data2016 = data2016[["FECHA", "EMISOR", "PRECIO"]]
print(data2016.columns)
print('Numero de companias cotizando en 2016:', data2016['EMISOR'].nunique())

```

```

print('Numero de cotizaciones por companias en 2016: ', data2016['EMISOR'].value_counts())
data2016 = data2016[~data2016['EMISOR'].isin(data2016['EMISOR'].value_counts()
        .it(12).pipe(lambda s: s[s].index))]
data2016['FECHA']=data2016['FECHA'].apply(pd.to_datetime, errors='coerce').dropna()
data2016mean=data2016.groupby([pd.PeriodIndex(data2016['FECHA'], freq="M"),
'EMISOR'])['PRECIO'].median().reset_index()
print(data2016mean.columns)
print('Dimensiones de los datos de 2016:', data2016mean.shape)
print('Numero de cotizaciones mensuales por companias en 2016: ',
data2016mean['EMISOR'].value_counts())
#%%
# Lectura de datos para 2017
data2017 = pd.read_excel('./Datos/CH2017.xls', sheet_name='2017')
print(data2017.head(10))
print(data2017.columns)
data2017.drop(data2017[data2017['PROCEDENCIA'] == 'G'].index, inplace=True)
data2017 = data2017[["FECHA", "EMISOR", "PRECIO"]]
print(data2017.columns)
print('Numero de companias cotizando en 2017:', data2017['EMISOR'].nunique())
print('Numero de cotizaciones por companias en 2017: ', data2017['EMISOR'].value_counts())
data2017 = data2017[~data2017['EMISOR'].isin(data2017['EMISOR'].value_counts()
        .it(12).pipe(lambda s: s[s].index))]
data2017['FECHA']=data2017['FECHA'].apply(pd.to_datetime, errors='coerce').dropna()
data2017mean=data2017.groupby([pd.PeriodIndex(data2017['FECHA'], freq="M"),
'EMISOR'])['PRECIO'].median().reset_index()
print(data2017mean.columns)
print('Dimensiones de los datos de 2017:', data2017mean.shape)
print('Numero de cotizaciones mensuales por companias en 2017: ',
data2017mean['EMISOR'].value_counts())
#%%
# Lectura de datos para 2018
data2018 = pd.read_excel('./Datos/2018-2019.xls', sheet_name='2018')
print(data2018.head(10))
print(data2018.columns)
data2018.drop(data2018[data2018['PROCEDENCIA'] == 'G'].index, inplace=True)
data2018 = data2018[["FECHA", "EMISOR", "PRECIO"]]
print(data2018.columns)
print('Numero de companias cotizando en 2018:', data2018['EMISOR'].nunique())
print('Numero de cotizaciones por companias en 2018: ', data2018['EMISOR'].value_counts())
data2018 = data2018[~data2018['EMISOR'].isin(data2018['EMISOR'].value_counts())

```

```

        .lt(12).pipe(lambda s: s[s.index]))
data2018['FECHA']=data2018['FECHA'].apply(pd.to_datetime, errors='coerce').dropna()
data2018mean=data2018.groupby([pd.PeriodIndex(data2018['FECHA'], freq="M"),
'EMISOR'])['PRECIO'].median().reset_index()
print(data2018mean.columns)
print('Dimensiones de los datos de 2018:', data2018mean.shape)
print('Numero de cotizaciones mensuales por companias en 2018: ',
data2018mean['EMISOR'].value_counts())
#%%%
# Lectura de datos para 2019
data2019 = pd.read_excel('./Datos/2018-2019.xls', sheet_name='2019')
print(data2019.head(10))
print(data2019.columns)
data2019.drop(data2019[data2019['PROCEDENCIA'] == 'G'].index, inplace=True)
data2019 = data2019[["FECHA", "EMISOR", "PRECIO"]]
print(data2019.columns)
print('Numero de companias cotizando en 2019:', data2019['EMISOR'].nunique())
print('Numero de cotizaciones por companias en 2019: ', data2019['EMISOR'].value_counts())
data2019 = data2019[~data2019['EMISOR'].isin(data2019['EMISOR'].value_counts())
        .lt(12).pipe(lambda s: s[s.index]))
data2019['FECHA']=data2019['FECHA'].apply(pd.to_datetime, errors='coerce').dropna()
data2019mean=data2019.groupby([pd.PeriodIndex(data2019['FECHA'], freq="M"),
'EMISOR'])['PRECIO'].median().reset_index()
print(data2019mean.columns)
print('Dimensiones de los datos de 2019:', data2019mean.shape)
print('Numero de cotizaciones mensuales por companias en 2019: ',
data2019mean['EMISOR'].value_counts())
#%%%
# Lectura de datos para 2020
data2020 = pd.read_excel('./Datos/2020-2021.xls', sheet_name='2020')
print(data2020.head(10))
print(data2020.columns)
data2020.drop(data2020[data2020['PROCEDENCIA'] == 'G'].index, inplace=True)
data2020 = data2020[["FECHA", "EMISOR", "PRECIO"]]
print(data2020.columns)
print('Numero de companias cotizando en 2020:', data2020['EMISOR'].nunique())
print('Numero de cotizaciones por companias en 2020: ', data2020['EMISOR'].value_counts())
data2020 = data2020[~data2020['EMISOR'].isin(data2020['EMISOR'].value_counts())
        .lt(12).pipe(lambda s: s[s.index]))
data2020['FECHA']=data2020['FECHA'].apply(pd.to_datetime, errors='coerce').dropna()

```

```

data2020mean=data2020.groupby([pd.PeriodIndex(data2020['FECHA'], freq="M"),
'EMISOR'])['PRECIO'].median().reset_index()
print(data2020mean.columns)
print('Dimensiones de los datos de 2020:', data2020mean.shape)
print('Numero de cotizaciones mensuales por companias en 2020: ',
data2020mean['EMISOR'].value_counts())
#%%
# Lectura de datos para 2021
data2021 = pd.read_excel('./Datos/2020-2021.xls', sheet_name='2021')
print(data2021.head(10))
print(data2021.columns)
data2021.drop(data2021[data2021['PROCEDENCIA'] == 'G'].index, inplace=True)
data2021 = data2021[['FECHA', "EMISOR", "PRECIO"]]
print(data2021.columns)
print('Numero de companias cotizando en 2021:', data2021['EMISOR'].nunique())
print('Numero de cotizaciones por companias en 2021: ', data2021['EMISOR'].value_counts())
data2021 = data2021[~data2021['EMISOR'].isin(data2021['EMISOR'].value_counts()
.lt(12).pipe(lambda s: s[s].index))]
data2021['FECHA']=data2021['FECHA'].apply(pd.to_datetime, errors='coerce').dropna()
data2021mean=data2021.groupby([pd.PeriodIndex(data2021['FECHA'], freq="M"),
'EMISOR'])['PRECIO'].median().reset_index()
print(data2021mean.columns)
print('Dimensiones de los datos de 2021:', data2021mean.shape)
print('Numero de cotizaciones mensuales por companias en 2021: ',
data2021mean['EMISOR'].value_counts())
#%%
# Lectura de datos para 2022
data2022 = pd.read_excel('./Datos/2022-2023.xls', sheet_name='2022')
print(data2022.head(10))
print(data2022.columns)
data2022.drop(data2022[data2022['PROCEDENCIA'] == 'G'].index, inplace=True)
data2022 = data2022[['FECHA', "EMISOR", "PRECIO"]]
print(data2022.columns)
print('Numero de companias cotizando en 2022:', data2022['EMISOR'].nunique())
print('Numero de cotizaciones por companias en 2022: ', data2022['EMISOR'].value_counts())
data2022 = data2022[~data2022['EMISOR'].isin(data2022['EMISOR'].value_counts()
.lt(12).pipe(lambda s: s[s].index))]
data2022['FECHA']=data2022['FECHA'].apply(pd.to_datetime, errors='coerce').dropna()
data2022mean=data2022.groupby([pd.PeriodIndex(data2022['FECHA'], freq="M"),
'EMISOR'])['PRECIO'].median().reset_index()

```

```

print(data2022mean.columns)
print('Dimensiones de los datos de 2022:', data2022mean.shape)
print('Numero de cotizaciones mensuales por companias en 2022: ',
data2022mean['EMISOR'].value_counts())
#%#%
# Lectura de datos para 2023
data2023 = pd.read_excel('./Datos/2022-2023.xls', sheet_name='2023')
print(data2023.head(10))
print(data2023.columns)
data2023.drop(data2023[data2023['PROCEDENCIA'] == 'G'].index, inplace=True)
data2023 = data2023[['FECHA', 'EMISOR', 'PRECIO']]
print(data2023.columns)
print('Numero de companias cotizando en 2023:', data2023['EMISOR'].nunique())
print('Numero de cotizaciones por companias en 2023: ', data2023['EMISOR'].value_counts())
data2023 = data2023[~data2023['EMISOR'].isin(data2023['EMISOR'].value_counts()
.lt(12).pipe(lambda s: s[s].index))]
data2023['FECHA']=data2023['FECHA'].apply(pd.to_datetime, errors='coerce').dropna()
data2023mean=data2023.groupby([pd.PeriodIndex(data2023['FECHA'], freq="M"),
'EMISOR'])['PRECIO'].median().reset_index()
print(data2023mean.columns)
print('Dimensiones de los datos de 2023:', data2023mean.shape)
print('Numero de cotizaciones mensuales por companias en 2023: ',
data2023mean['EMISOR'].value_counts())

#=====
#=====
# Combinacion de archivos anuales
#=====
#=====
#%#%
# Integracion datos 2013 con 2014
datacombinada20132014= pd.merge(data2013mean, data2014mean, how='outer')
print('Las dimensiones del dato combinado para 2013-2014 es:', datacombinada20132014.shape)
#%#%
# Integracion datos 2013-2014 con 2015
datacombinada20132015= pd.merge(datacombinada20132014, data2015mean, how='outer')
print('Las dimensiones del dato combinado para 2013-2015 es:', datacombinada20132015.shape)
#%#%
# Integracion datos 2013-2015 con 2016
datacombinada20132016= pd.merge(datacombinada20132015, data2016mean, how='outer')

```

```

print('Las dimensiones del dato combinado para 2013-2016 es:', datacombinada20132016.shape)
#%%
# Integracion datos 2013-2016 con 2017
datacombinada20132017= pd.merge(datacombinada20132016, data2017mean, how='outer')
print('Las dimensiones del dato combinado para 2013-2017 es:', datacombinada20132017.shape)
#%%
# Integracion datos 2013-2017 con 2018
datacombinada20132018= pd.merge(datacombinada20132017, data2018mean, how='outer')
print('Las dimensiones del dato combinado para 2013-2018 es:', datacombinada20132018.shape)
#%%
# Integracion datos 2013-2018 con 2019
datacombinada20132019= pd.merge(datacombinada20132018, data2019mean, how='outer')
print('Las dimensiones del dato combinado para 2013-2019 es:', datacombinada20132019.shape)
#%%
# Integracion datos 2013-2019 con 2020
datacombinada20132020= pd.merge(datacombinada20132019, data2020mean, how='outer')
print('Las dimensiones del dato combinado para 2013-2020 es:', datacombinada20132020.shape)
#%%
# Integracion datos 2013-2020 con 2021
datacombinada20132021= pd.merge(datacombinada20132020, data2021mean, how='outer')
print('Las dimensiones del dato combinado para 2013-2021 es:', datacombinada20132021.shape)
#%%
# Integracion datos 2013-2021 con 2022
datacombinada20132022= pd.merge(datacombinada20132021, data2022mean, how='outer')
print('Las dimensiones del dato combinado para 2013-2022 es:', datacombinada20132022.shape)
#%%
# Integracion datos 2013-2022 con 2023
datacombinada20132023= pd.merge(datacombinada20132022, data2023mean, how='outer')
print('Las dimensiones del dato combinado para 2013-2023 es:', datacombinada20132023.shape)

#%%
# Analitica Inicial
print("Numero de cotizaciones por compania: ",
datacombinada20132023['EMISOR'].value_counts())
datacombinada20132023 =
datacombinada20132023[~datacombinada20132023['EMISOR'].isin(datacombinada20132023['EMISO
R'].value_counts()
                               .it(48).pipe(lambda s: s[s.index]))]
print("Numero de cotizaciones por compania: ",
datacombinada20132023['EMISOR'].value_counts())

```

```
###  
# Selección serie temporal por empresa  
nombreempresa = 'INDUSTRIAS ALES'  
empresa = datacombinada20132023.loc[datacombinada20132023['EMISOR']== nombreempresa]  
empresa = empresa.reset_index(drop=True)  
print(empresa.head(10))  
print(empresa.shape)  
###  
# Generación de gráfica  
ax = plt.gca()  
empresa.plot(kind='line', x='FECHA', y='PRECIO', ax=ax)  
plt.title(nombreempresa)  
plt.ylabel("USD", size = 12)  
plt.show()  
# %%  
empresa["FECHA"] = empresa["FECHA"].astype(str)+'-01'  
empresa["FECHA"] = pd.to_datetime(empresa["FECHA"], format = '%Y-%m-%d')  
###  
# generación de archivo csv  
empresa = empresa[["FECHA", "PRECIO"]]  
archivoname = "IndustriasAles.csv"  
empresa.to_csv('./resultados/'+archivoname, index=False)
```

Anexo 2: Script Interpolador.py

```

# %%
import pandas as pd
import numpy as np
# %%
# Lectura de archivo csv a interpolar
datocsv = pd.read_csv('./resultados/SanCarlos.csv')
datocsv['FECHA']=pd.to_datetime(datocsv['FECHA'])
datocsv['FECHA']=datocsv['FECHA'].dt.strftime('%Y-%m-%d')
print(datocsv.head)
print('Formato de columna FECHA: ', datocsv['FECHA'].dtype)
idx = pd.date_range(start=datocsv['FECHA'].min(), end=datocsv['FECHA'].max(), freq="MS")
datocsv.index = pd.DatetimeIndex(datocsv['FECHA'])
datocsv = datocsv.set_index(datocsv.index).reindex(idx, fill_value=np.nan)
print(datocsv.columns)
print(datocsv.head)
# %%
# Interpolacion FECHA
datocsv2 = datocsv.copy()
datocsv2['PRECIO'] = datocsv2['PRECIO'].fillna(method='pad')
# %%
#index to column
datocsv2.reset_index(inplace=True)
datocsv2 = datocsv2.rename(columns={'index':'FECHA2'})
datocsv2 = datocsv2[["FECHA2", "PRECIO"]]
datocsv2 = datocsv2.rename(columns={'FECHA2':'FECHA'})
datocsv2['FECHA']=datocsv2['FECHA'].dt.strftime('%Y-%m-%d')
# %%
# Exportacion de dataframes a CSV
# generacion de archivo csv
datocsv2.to_csv('./resultados/SanCarlosInt.csv', index=False)

```

Anexo 3: Script Fusion.py

```

# %%
# importacion librerias
import pandas as pd
import numpy as np
# %%
# lectura de csvs
file1 = pd.read_csv('./resultados/CorporacionFavorita.csv')
file2 = pd.read_csv('./resultados/BancoGuayaquilInt.csv')
file3 = pd.read_csv('./resultados/BancoPichinchaInt.csv')
file4 = pd.read_csv('./resultados/BVQInt.csv')
file5 = pd.read_csv('./resultados/CerveceriaNacionalInt.csv')
file6 = pd.read_csv('./resultados/ConclinaInt.csv')
file7 = pd.read_csv('./resultados/HolcimInt.csv')
file8 = pd.read_csv('./resultados/IndustriasAlesInt.csv')
file9 = pd.read_csv('./resultados/MutualistaPichinchaInt.csv')
file10 = pd.read_csv('./resultados/ProdubancoInt.csv')
file11 = pd.read_csv('./resultados/SanCarlosInt.csv')
# %%
# Fusion de archivos csvs
file12 = file1.merge(file2, how='outer', on='FECHA')
file12 = file12.rename(columns={'PRECIO_x': 'CorporacionFavorita',
                              'PRECIO_y': 'BancoGuayaquil'})
# %%
file13 = file12.merge(file3, how='outer', on='FECHA')
file13 = file13.rename(columns={'PRECIO': 'BancoPichincha'})
# %%
file14 = file13.merge(file4, how='outer', on='FECHA')
file14 = file14.rename(columns={'PRECIO': 'BVQ'})
# %%
file15 = file14.merge(file5, how='outer', on='FECHA')
file15 = file15.rename(columns={'PRECIO': 'CerveceriaNacional'})
# %%
file16 = file15.merge(file6, how='outer', on='FECHA')
file16 = file16.rename(columns={'PRECIO': 'Conclina'})
# %%
file17 = file16.merge(file7, how='outer', on='FECHA')
file17 = file17.rename(columns={'PRECIO': 'Holcim'})
# %%
file18 = file17.merge(file8, how='outer', on='FECHA')

```

```
file18 = file18.rename(columns={'PRECIO':'IndustriasAles'})
# %%
file19 = file18.merge(file9, how='outer', on='FECHA')
file19 = file19.rename(columns={'PRECIO':'MutualistaPichincha'})
# %%
file110 = file19.merge(file10, how='outer', on='FECHA')
file110 = file110.rename(columns={'PRECIO':'Produbanco'})
# %%
file111 = file110.merge(file11, how='outer', on='FECHA')
file111 = file111.rename(columns={'PRECIO':'SanCarlos'})
# %%
# Generacion de CSV fusionado
file111.to_csv('./resultados/FusionadoEmisores.csv', index=False)
```

Anexo 4: Código BFAST

```
library(xts)
library(bfast)
library(tibble)
library(dplyr)
library(timetk)
library(tidyquant)
library(tseries)

#Lectura de datos
dollar_rate <-
read.csv("/Users/Yusleidy/Dropbox/Comun/Pycharm/mac/stockanalysis/resultados/BancoGuayaquilIntR.
csv", stringsAsFactors = FALSE)
dollar_rate_ts <- xts(dollar_rate$PRECIO, order.by = as.POSIXct(dollar_rate$FECHA))
plot(dollar_rate_ts, main = "BVQ", xlab = "Date", ylab = "USD$")

# Creacion de objeto de serie temporal

class(dollar_rate)
colnames(dollar_rate)
head(dollar_rate)
class(dollar_rate$FECHA)
class(dollar_rate$PRECIO)
sbux.ts = ts(data=dollar_rate$PRECIO, frequency = 12, start=c(2013,1), end=c(2022,12))
class(sbux.ts)
start(sbux.ts)
end(sbux.ts)
time(sbux.ts)

# Test de Estacionariedad
componentes <- decompose(sbux.ts)
plot(componentes)

#adf.test(diff(log(sbux.ts)), alternative='stationary', k=0)
#plot(decompose(diff(log(sbux.ts))))

# Corrida de BFAST
rdist <- 10/length(sbux.ts)
```

```
fit<-bfast(sbox.ts, h=rdist, season='harmonic', max.iter = 1, breaks = 3, type = "OLS-MOSUM")
#plot(fit, type = "components", ANOVA = TRUE, largest = TRUE)
plot(fit, type = "trend", ANOVA = FALSE, largest = FALSE, main= 'San Carlos')
fit$output
componentes$trend
fit$Magnitude
fit$Time
```

Anexo 5: Código CUSUM

```

library(zoo)      # time series library
library(ggplot2) # graphing library
library(readxl)  # reading excel files library
library(strucchange) # library implementing breakpoint analysis
library(ggfortify) # extension for ggplot time series graphing

# Read and transform data
company <- 'BVQInt'
#data <- read.csv("C:\\Users\\Yusleidy\\Dropbox\\1Yusleidy\\Maestría\\2023\\Tesis\\csvs\\Banco
GuayaquilInt.csv", stringsAsFactors = FALSE)
data.ts = ts(data=data$PRECIO, frequency = 12, start=c(2013,1), end=c(2022,12))
autoplot(data.ts) + labs(title=paste("Precio histórico acciones: ",
company),x="FECHA",y="PRECIO")
start_year = time(data.ts)[1]

# Plot the data and CUSUM & MOSUM
autoplot(data.ts) + labs(title=paste("Percentage change of RGDP per year in",company),
x="year", y="percent in decimal")
# cusum and mosum for residuals (value - mean)
#plot cumsum
CUSUM = cumsum(data.ts- mean(data.ts))
CUSUM <- ts(CUSUM,start =start_year)
autoplot(CUSUM)+ geom_hline(yintercept = 0,color="blue")+labs(title="Cumulative
Sum", x="year", y="percent in decimal")

# plot moving sum
MOSUM = rollapply(data.ts - mean(data.ts), 15, sum)
autoplot(MOSUM)+ geom_hline(yintercept = 0,color="blue")+labs(title="Moving Sum
from 15 observations", x="year", y="percent in decimal")

# plot rec-cumsum (mean of all observations prior to given time)

```

```

rec_cusum <- numeric(length(data.ts))
for (i in 1:length(data.ts)){
  rec_cusum[i] = mean(data.ts[1:(i-1)])
}
rec_cusum <- ts(rec_cusum,start = start_year,frequency = 12)
autoplot(rec_cusum)+labs(title="Recursive Cumulative Sum", x="year", y="percent in
decimal")

# calculate residual sum of squares
rss = sapply(5:(length(data.ts)-5), function(i) {
  before <- 1:i
  after <- (i+1):length(data.ts)
  res <- c(Nile[before] - mean(Nile[before]), Nile[after] - mean(Nile[after]))
  sum(res^2)
})

rss <- ts(data.ts,start=start_year-1+5,frequency=12)
autoplot(rss) + labs(title = "Residual Sum of Squares",x="Year",y="RSS")

# find suspected breakpoint
breakpoint <- time(rss)[which.min(rss)]
#breakpoint <- time(data.ts)[which.min(data.ts)]
plot(data.ts)
abline(v=breakpoint, col="red",lty=2)
lines(ts(predict(lm((data.ts[1:(breakpoint-start_year+1)]
1)),start=start_year,freq=12),col='darkgreen',lwd=2) ~
lines(ts(predict(lm((data.ts[(breakpoint-start_year+1):length(data.ts)]
1)),start=breakpoint,freq=12),col='darkgreen',lwd=2) ~

#-----
# Strucchange based calculations
# 1. Simple model country_gdp ~ 1 (y = β0) β0 = mean

```

```

# F statistics at 5% significance level, h=0.1 (partition size)
fs <- Fstats(data.ts ~ 1,from=0.1)
plot(fs,main="F test")
cat("Potential breakpoint form F test at:", time(data.ts)[fs$breakpoint],"\n")

# test the null hypothesis that the GDP growth remains constant over the years
# compute OLS-based CUSUM & MOSUM process and plot

par(mfrow=c(2,2))
ocus <- efp(data.ts ~ 1, type = "OLS-CUSUM")
omos <- efp(data.ts ~ 1, type = "OLS-MOSUM")
rmos <- efp(data.ts ~ 1, type = "Rec-CUSUM")
rcus <- efp(data.ts ~ 1, type = "Rec-MOSUM")
plot(ocus)
plot(omos)
plot(rmos)
plot(rcus)
par(mfrow=c(1,1))

componentes <- decompose(data.ts)
plot(componentes)

# finding date of the breakpoint
bp <- breakpoints(data.ts ~ 1)
for(i in bp$breakpoints){cat("Breakpoint found at year:",time(data.ts)[i],"\n")}
# finding segmentation of the data
bfac <- breakfactor(bp, breaks = length(bp$breakpoints))
# model
fm <- lm(data.ts ~ bfac - 1)
plot(bp)
autoplot(bp)
bp

plot(data.ts, ylab="PRECIO")

```

```
lines(ts(predict(fm),start=start_year,freq=12), col='darkgreen',lwd=2)  
componentes$trend
```