



Universitat de Lleida

Análisis de modelos de valoración de activos y búsqueda factores de riesgo en mercados emergentes latinoamericanos en tiempo de crisis sanitaria

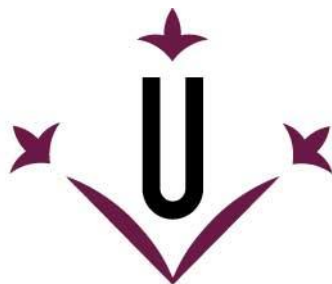
Pedro Antonio González Tapia

<http://hdl.handle.net/10803/689302>



Análisis de modelos de valoración de activos y búsqueda factores de riesgo en mercados emergentes latinoamericanos en tiempo de crisis sanitaria està subjecte a una llicència de [Reconeixement 4.0 No adaptada de Creative Commons](https://creativecommons.org/licenses/by/4.0/)

(c) 2023, Pedro Antonio González Tapia



Universitat de Lleida

TESIS DOCTORAL

**“Análisis de modelos de valoración de activos y
búsqueda factores de riesgo en mercados
emergentes latinoamericanos en tiempo de
crisis sanitaria”**

Pedro Antonio González Tapia

Memoria presentada para optar al grado de Doctor por la
Universitat de Lleida, Programa de Doctorado en Derecho y
Administración de Empresas

Director
Dr. José Luis Gallizo Larraz

2023

A mi esposa Viviana Urriola que ha sido parte importante de mi desarrollo profesional y
a mis hijos Juan Pablo, Francisco y Catalina.

Agradecimientos

Este es un objetivo de muchos años, cuando era pequeño siempre me cautivo el hecho de darle sentido a las cosas. Sobre todo, en el ámbito de las ciencias sociales, admiraba a las personas que realizaban investigaciones y que contribuían no sólo a un sector de la ciencia, sino que también alimentaban mi necesidad de aprender a investigar un tema. Entendí que investigar es un proceso que hay que vivirlo y nos deja un camino abierto para nuevos trabajos. Esto es el comienzo.

En este trabajo no puedo dejar de agradecer a las personas que contribuyeron de forma muy generosa con su tiempo y dedicación, como es el caso de mi director de tesis doctor José Luis Gallizo Larraz, sin sus recomendaciones y desafíos no hubiese sido posible culminar el trabajo que supone una tesis doctoral. También quiero agradecer el trabajo realizado a los evaluadores de la tesis doctoral: Dr. Cristián Troncoso Valverde y Dr. Juan Gallegos Mardones, que con mucha generosidad han dedicado su tiempo para la revisión de este trabajo, y aportado recomendaciones muy valiosas que hicieron que mejorará significativamente este trabajo.

También agradezco a mi compañero de estudios doctorales, al doctor José Navarrete Oyarce, por su ayuda, orientación en este período y constante contacto que sirvió de ánimo y ganas de terminar lo empezado, cuando las distracciones y obligaciones cotidianas a uno lo alejan del término de este proceso.

A mi familia un especial agradecimiento de este largo camino de estudios, que no sólo se limita a este trabajo, donde en muchos casos importantes en sus vidas estuve ausente, pero ellos comprendían mi necesidad de desarrollarme. Especialmente a mi esposa que ha sido el motor de mis logros y desarrollo, Viviana Urriola y mis hijos Juan Pablo, Francisco y Catalina.

Alumno: Pedro Antonio González Tapia.

Índice

Capítulo 1 : Introducción.....	11
1.1.- Identificación del problema a investigar.....	12
1.2.- Objetivo del trabajo de investigación	15
1.3.- Metodología de la investigación.....	17
1.4.- Resultados.....	33
1.5.- Estructura de los capítulos.	42
Capítulo 2 : Eficiencia de mercado en su forma débil y aplicación de prueba de estacionariedad al modelo de valoración CAPM en el mercado bursátil chileno.	45
2.1.- Resumen del Capítulo.....	46
2.2.- Introducción	48
2.3.- Hipótesis de Eficiencia de Mercado (Efficient Market Hypothesis o EMH)	49
2.4.- Modelo CAPM (Capital Asset Pricing Model).....	50
2.5.- Metodología.....	59
2.5.1.- Paseo aleatorio (Random Walk).....	59
2.5.2.- Pruebas de estacionariedad	60
2.5.3.- Test de Dickey-Fuller (DF).....	60
2.5.4.- Test de Dickey-Fuller Aumentado (ADF)	61
2.5.5.- Test en dos etapas	62
2.5.6.- Test Black, Jensen, and Scholes (BJS).....	64
2.5.7.- Test Black, Jensen, and Scholes – Fama Macbeth	67
2.5.8.- Datos utilizados.....	69
2.6.- Resultados.....	72
2.7.- Conclusiones del capítulo.....	81
Capítulo 3 : Impacto del COVID-19 en la Bolsa de Valores por Sector Industrial en Chile: Una Sobrerreacción Adversa.....	85
3.1.- Resumen del capítulo.....	86
3.2.- Introducción	87
3.3.- Metodología y datos.....	90

3.3.1.- Calendario de pandemia de COVID-19.....	94
3.3.2.- Metodología Estudio de Eventos.....	97
3.3.3.- Modelo de rendimiento medio ajustado: MRPA (método A).....	101
3.3.4.- Modelo de rendimiento de mercado ajustado: MRMA (método B)	102
3.3.5.- Modelo de mercado: MM (método C)	102
3.3.6.- Rendimientos anormales de compra y retención (BHAR).....	103
3.3.7.- La significancia estadística contrasta con la rentabilidad extraordinaria.....	104
3.3.8.- Análisis de Reacción a Nueva Información en el Mercado	105
3.4.- Resultados.....	106
3.5.- Discusión.....	117
3.6.- Conclusión del capítulo	121
Capítulo 4 : Desempeño de modelos de valoración derivados del modelo CAPM, en periodo antes de pandemia y en crisis sanitaria, en el mercado bursátil chileno.....	124
4.1.- Resumen del capítulo.....	125
4.2.- Introducción	126
4.3.- Revisión bibliográfica.....	128
4.4.- Metodología y datos.....	135
4.4.1.- Modelo Capital Asset Pricing Model (CAPM)	135
4.4.2.- Modelo Fama French Tres Factores.....	135
4.4.3.- Modelo de Fama Cahart de Cuatro Factores	136
4.4.4.- Modelo Fama French Cinco Factores	137
4.4.5.- Obtención de los factores de riesgo.....	138
4.5.- Metodología.....	142
4.5.1.- Test GRS	149
4.6.- Resultados.....	151
4.6.1.- Análisis panel size – ratio B/M.....	154
4.6.2.- Análisis panel Size – Rentabilidad Operacional.....	158
4.6.3.- Análisis panel Size – inversiones.....	161

4.6.4.- Análisis panel Size – Momentum del retorno.....	165
4.6.5.- Análisis del rendimiento de los modelos	169
4.7.- Conclusión del capítulo	172
Capítulo 5 : Sentimiento de los inversores en la crisis sanitaria y comportamiento de los índices bursátiles del MILA.....	175
5.1.- Resumen del capítulo.....	176
5.2.- Introducción	177
5.3.- Revisión de Literatura.....	180
5.4.- Datos y Metodología	184
5.4.1.- Mercado integrado Latinoamericano	184
5.4.2.- Prueba de causalidad de Granger	190
5.4.3.- Pruebas de estacionariedad	191
5.4.4.- Test de Dickey-Fuller (DF).....	191
5.4.5.- Test de Dickey-Fuller Aumentado (ADF)	192
5.5.- Resultados.....	193
5.5.1.- Resultado de Causalidad de Granger	198
5.6.- Conclusión del capítulo	206
Capítulo 6 : Modelo de Fama Cahart Extendido con factores de comportamiento y volatilidad como propuesta en tiempos de crisis, aplicado en los índices que componen el MILA.....	209
6.1.- Resumen del capítulo.....	210
6.2.- Introducción	211
6.3.- Revisión de la literatura.....	213
6.4.- Metodología y datos.....	221
6.5.- Metodología.....	228
6.5.1.- Prueba al modelo multifactorial de comportamiento.....	230
6.6.- Resultados.....	231
6.7.- Conclusión del capítulo	240
Capítulo 7 : Incidencia de búsquedas en internet por Google Trends, sobre los precios de los índices de mercados bursátiles del Mercado Integrado Latinoamericano (MILA)	243

7.1.- Resumen del capítulo.....	244
7.2.- Introducción	245
7.3.- Revisión de Literatura.....	247
7.4.- Metodología y datos.....	255
7.4.1.- Google Trends	257
7.4.2.- Search Volume Índices (SVI)	258
7.4.3.- Proceso de selección de términos de búsquedas relevantes.....	260
7.4.4.- Modelo para estimar por la regresión LASSO.....	261
7.5.- Resultados.....	263
7.6.- Conclusión del capítulo	278
Capítulo 8 : Conclusiones	281
8.1.- Introducción	282
8.2.- Conclusiones.	283
8.3.- investigaciones futuras.	289
Bibliografía.....	292
Anexos.....	323

Resumen

En el proceso de valoración de activos, es esencial considerar los factores de riesgo externos que impactan en el comportamiento de los agentes del mercado. Esta consideración adquiere aún más importancia durante periodos de alta incertidumbre. Por lo tanto, resulta fundamental contar con un modelo sólido que permita incorporar y modelar adecuadamente dichos factores en el proceso de valoración de acciones, especialmente en países como Chile y México, donde las inversiones incluyen fondos de pensiones que se negocian en las bolsas de valores locales.

En particular, es relevante llevar a cabo un estudio en el mercado chileno y extrapolar los resultados a otros países latinoamericanos emergentes debido a la futura fusión de las bolsas de valores de Chile, Colombia y Perú. Cabe destacar que Chile ocupa el segundo lugar en términos de volumen bursátil en el MILA (Mercado Integrado Latinoamericano) y es el principal mercado bursátil en comparación con Colombia y Perú. Con esta fusión de bolsas de valores, se espera que se convierta en la segunda bolsa de valores más grande de América Latina.

La llegada del COVID-19 generó incertidumbre en los mercados, provocando caídas históricas. Sin embargo, esta crisis también brindó la oportunidad de investigar cómo la información relacionada con la pandemia afecta al mercado bursátil en Chile, así como evaluar la eficiencia del mercado chileno mediante un estudio de eventos. Además, se exploraron factores externos al mercado, como los índices de volatilidad VIX, el sentimiento de miedo y codicia en las criptomonedas (Bitcoin) y los comentarios en Twitter sobre los activos del SP&500 e índice construido con los datos de la pandemia del COVID-19 (nuevos casos confirmados). Los resultados demostraron que estos factores contenían información relevante para los índices bursátiles de Chile, Colombia y México, y se estableció una relación causal entre ellos y los índices mediante la aplicación de la causalidad de Granger.

A partir de estos hallazgos, se sugiere la necesidad de incorporar estos factores en los modelos de valoración durante crisis sanitarias, con el objetivo de mejorar la predicción de los precios de los activos. Se propone un modelo de valoración extendido basado en el modelo de cuatro factores de Cahart, al cual se le agregan los factores de riesgo externos mencionados anteriormente.

En el último capítulo de la tesis, se analiza la intensidad de búsqueda de términos relacionados con sentimientos positivos y negativos en la plataforma Google Trends como un factor adicional. Los resultados obtenidos demuestran que estas variables capturan el sentimiento de los inversionistas en el período de estudio. Esto resalta el papel crucial de la inteligencia artificial y los datos de Internet en la valoración de activos en el futuro.

Abstract

In the process of asset valuation, it is essential to consider external risk factors that impact the behavior of market agents. This consideration becomes even more important during periods of high uncertainty. Therefore, it is fundamental to have a robust model that allows for the incorporation and proper modeling of these factors in the stock valuation process, especially in countries like Chile and Mexico, where investments include pension funds traded on local stock exchanges.

In particular, it is relevant to conduct a study in the Chilean market and extrapolate the results to other emerging Latin American countries due to the future merger of the stock exchanges of Chile, Colombia, and Peru. It is worth noting that Chile ranks second in terms of stock market volume in the MILA (Latin American Integrated Market) and is the main stock market compared to Colombia and Peru. With this merger of stock exchanges, it is expected to become the second largest stock exchange in Latin America.

The arrival of COVID-19 generated uncertainty in the markets, causing historic declines. However, this crisis also provided an opportunity to investigate how pandemic-related information affects the stock market in Chile, as well as evaluate the efficiency of the Chilean market through an event study. Additionally, external factors to the market were explored, such as VIX volatility indices, sentiment of fear and greed in cryptocurrencies (Bitcoin), and Twitter comments about SP&500 assets and an index constructed with COVID-19 pandemic data (new confirmed cases). The results showed that these factors contained relevant information for the stock indices of Chile, Colombia, and Mexico, and a causal relationship was established between them and the indices through the application of Granger causality.

Based on these findings, the need to incorporate these factors into valuation models during health crises is suggested in order to improve asset price prediction. An extended valuation model is proposed based on the four-factor model by Cahart, to which the aforementioned external risk factors are added.

In the last chapter of the thesis, the intensity of search terms related to positive and negative sentiments on the Google Trends platform is analyzed as an additional factor. The obtained results demonstrate that these variables capture investor sentiment in the study period. This highlights the crucial role of artificial intelligence and Internet data in asset valuation in the future.

Resum

En el procés de valoració d'actius, és essencial considerar els factors de risc externs que impacten en el comportament dels agents del mercat. Aquesta consideració adquireix encara més importància durant períodes d'alta incertesa. Per tant, resulta fonamental comptar amb un model sòlid que permeti incorporar i modelar adequadament aquests factors en el procés de valoració d'accions, especialment en països com Xile i Mèxic, on les inversions inclouen fons de pensions que es negocien a les borses de valors locals.

En particular, és rellevant dur a terme un estudi en el mercat xilè i extrapolar els resultats a altres països llatinoamericans emergents a causa de la futura fusió de les borses de valors de Xile, Colòmbia i Perú. Cal destacar que Xile ocupa el segon lloc en termes de volum borsari al MILA (Mercat Integrat Llatinoamericà) i és el principal mercat borsari en comparació amb Colòmbia i Perú. Amb aquesta fusió de borses de valors, s'espera que es converteixi en la segona borsa de valors més gran d'Amèrica Llatina.

L'arribada de la COVID-19 va generar incertesa en els mercats, provocant caigudes històriques. No obstant això, aquesta crisi també va oferir l'oportunitat d'investigar com la informació relacionada amb la pandèmia afecta el mercat borsari a Xile, així com avaluar l'eficiència del mercat xilè mitjançant un estudi d'esdeveniments. A més, es van explorar factors externs al mercat, com els índexs de volatilitat VIX, el sentiment de por i avarícia en les criptomonedes (Bitcoin) i els comentaris a Twitter sobre els actius de l'SP&500 i l'índex construït amb les dades de la pandèmia de la COVID-19 (nous casos confirmats). Els resultats van demostrar que aquests factors contenien informació rellevant per als índexs borsaris de Xile, Colòmbia i Mèxic, i es va establir una relació causal entre ells i els índexs mitjançant l'aplicació de la causalitat de Granger.

A partir d'aquests troballes, es suggereix la necessitat d'incorporar aquests factors en els models de valoració durant crisis sanitàries, amb l'objectiu de millorar la predicció dels preus dels actius. Es proposa un model de valoració ampliat basat en el model de quatre factors de Cahart, al qual s'hi afegeixen els factors de risc externs esmentats anteriorment.

En l'últim capítol de la tesi, s'analitza la intensitat de cerca de termes relacionats amb sentiments positius i negatius a la plataforma Google Trends com un factor addicional. Els resultats obtinguts demostren que aquestes variables capturen el sentiment dels inversors en el període d'estudi. Això posa de relleu el paper crucial de la intel·ligència artificial i les dades d'Internet en la valoració d'actius en el futur.

Capítulo 1 : Introducción

1.1.- Identificación del problema a investigar

En los mercados financieros, un elemento esencial para analizar el precio de los activos, son los modelos de fijación de precios y de cómo estos modelos ayudan a la eficiencia de estos mercados. Estos modelos matemáticos son una herramienta fundamental para el proceso de toma de decisiones en el mercado de valores.

Las decisiones que toman los agentes en el mercado juegan un rol fundamental en la rentabilidad y formas de eficiencia financiera establecida en la hipótesis de mercados eficientes de (Fama, Eugene, 1970). Desde sus inicios en la década del sesenta, los modelos de valoración han estado sometidos a ajustes en los factores de riesgo, y además se han realizado varias comprobaciones e investigaciones en distintos mercados, donde se contrastan tanto su potencial en la aplicación, como la falta de captura de riesgos de sus variables independientes.

La relevancia de revisar la eficiencia de mercado hoy en día en la emergencia sanitaria, es debido a que los principales mercados financieros del mundo se comportaron ineficientes frente a la llegada de la pandemia del COVID-19, donde se abre de nuevo el debate acerca de que los mercados se mantengan en alguna de las formas de eficiencia establecidas por Eugene Fama, y con este actuar se pueden anticipar políticas públicas que permitan resguardar a los países de fuertes pérdidas que provoca este tipo de crisis en los mercados bursátiles. Mercados financieros desarrollados actuaron con ineficiencia como lo es el índice SP&500, el que cayó a un mínimo de 2.237 puntos el 23 de marzo de 2020, sólo un mes después de alcanzar un máximo de 3.386 puntos. Al final del trimestre, el índice cotizaba alrededor de niveles de 2.600 puntos. Este cambio repentino en los niveles de precios merece atención, ya que es probable que cambios tan grandes se deban a razones que van más allá de los fundamentos financieros. Mientras algunos creen que el pánico en torno a la crisis de COVID-19 es exagerado, otros sostienen que la situación actual es la nueva normalidad y representa una corrección de las valoraciones impracticablemente altas antes de la irrupción de la pandemia. (Lalwani & Meshram, 2020). (Wang & Wang, 2021). Las desviaciones de la eficiencia del mercado financiero se ven más en los mercados bursátiles de los Estados Unidos y el Reino Unido. durante el brote de COVID-19 que en otros mercados bursátiles (Ozkan, 2021)

Frente a esta ineficiencia de los mercados financieros mundiales, es importante revisar el actuar de los agentes en el mercado, este es otro elemento esencial para

revisar sobre todo en entornos enfrentados a aumentos de incertidumbre, como lo es el período de pandemia del COVID-19. En economía financiera, este tema, tiene dos objetos principales de estudio, los cuales son el comportamiento de los individuos en la asignación de sus recursos en un entorno incierto y el papel que juegan las organizaciones económicas y de los mercados e instituciones, en facilitar las asignaciones de estos recursos (Marín & Gonzalo, 2011). De esta aseveración se pueden desprender dos consecuencias: una es que las decisiones en el mercado están influenciadas por el comportamiento de las personas y otra es qué motiva a estos inversionistas a tomar una u otra decisión que afecte al mercado. Esto último es como las personas enfrentan el riesgo en el mercado, riesgo entendido como incertidumbre o niveles de temor, como también frente a un aumento de confianza en el mercado en un momento determinado. El desafío en las finanzas corporativas es cómo estos comportamientos se pueden modelar o llevar esta información hacia el proceso de valoración de acciones, para que estén consideradas en los precios de los activos. Este elemento representa la primera motivación para investigar hoy en día en la teoría financiera y en esta tesis en particular, específicamente con la aplicación de estudios en el mercado chileno e índices del Mercado Integrado Latino Americano (MILA).

Cabe mencionar la importancia de contar con un buen modelo en tiempos de crisis, esto es debido a que, en Chile y México, además de las inversiones tradicionales, tiene un componente social, ya que se transan los fondos de pensiones en las bolsas de valores locales.

La relevancia de realizar este estudio desde el mercado chileno hacia los demás mercados en América Latina, e interpolar los resultados del rendimiento de los modelos a los demás países latinoamericanos emergentes, excluido Brasil, es la futura fusión de las operaciones de las bolsas de valores de Chile, Colombia y Perú, donde Chile es el segundo país que tiene mayor volumen bursátil de los cuatro países que componen el MILA y en comparación con Colombia y Perú, es el principal mercado bursátil. Cabe señalar que desde 2018, comenzó la iniciativa de fusionar las tres bolsas de valores latinoamericanas (Chile, Colombia y Perú). Esta fusión se concretaría a fines de 2023, donde se espera que este mercado sea el segundo más grande en volumen bursátil de Latinoamérica después de Brasil, la fusión de estas bolsas generará un mercado de 800.000 millones de dólares (Lexlatin, 2023). El ampliar estos mercados llevará beneficios que impactaran en el beneficio y liquidez de las organizaciones, como también en el crecimiento económico de los países.

El modelo de valoración de mayor utilización es el modelo CAPM (Capital Asset Price Model), el cual fue desarrollado por cuatro economistas (Treyner, 1961) (Sharpe W. , 1964) (Lintner, 1965) (Mossin, 1966), que trabajaron en la problemática por separado, a partir del planteamiento de la teoría de carteras de (Markowitz, 1952). El modelo se hace popular por lo sencillo y fácil de aplicar en la valoración y pronóstico de los activos, ya que es mucho más complejo valorar las acciones, desde los registros contables financieros de las empresas, por los métodos de flujo de caja descontados o por múltiples comparables entre organizaciones de un mismo sector, que hacerlo sobre las cotizaciones en bolsa.

A lo largo del tiempo la aplicación del modelo de un factor de riesgo, que considera el factor endógeno de premio por riesgo, que es la diferencia entre el retorno de mercado y el retorno del activo libre de riesgo, fue evidenciando fallas en distintos mercados, dando cuenta de varios ajustes, agregando los siguientes factores de riesgo: el factor tamaño (SMB), valor (HML), rentabilidad operacional (RMW), inversión (CMA), momentum (WML). Estos factores forman parte de los modelos de valoración que se van a evaluar en este trabajo de investigación, los cuales son: Fama French de tres factores, Fama Cahart de cuatro de factores y Fama French de Cinco factores, existen muchas otras modificaciones que han involucrado tanto factores macroeconómicos, como también realizando cambios de variables del modelo original, en este caso se puede mencionar el modelo Zero Beta, el que elimina la tasa libre de riesgo. (Black, Jensen, & Scholes, 1972) u otros que agregan más factores de riesgo como lo son los modelos multifactoriales, como lo es el APT (Arbitraje Pricing Theory) (Ross, 1976).

Sin perjuicio de los factores de riesgo que se han revisado en las últimas décadas, que tienen principalmente su origen en la macroeconomía, y otros más actuales e innovadores como lo son variables que provienen desde condiciones climáticas a partir de cambios experimentados de temperatura o sequías prolongadas que afectan a economías en el mundo, esta investigación se centra en la búsqueda de factores que capturen el sentir de los inversionistas. Estas variables de riesgo buscan superar el supuesto de racionalidad de los modelos tradicionales, bajo la premisa de que los seres humanos no necesariamente son aversos al riesgo. (Elton, Gruber, & Busse, 2002). En este trabajo se utilizará el periodo de pandemia del Covid-19, para probar factores de riesgo basado en el temor de los agentes del mercado, frente a la contingencia.

Las finanzas conductuales tienen una gran oportunidad y potencial para convertirse en un complemento a la teoría financiera clásica, que permita la

realización de una investigación financiera más realista y de utilidad (Fromlet, 2001). En este sentido se embarca este trabajo, que se hace cargo de buscar el complemento que ha surgido de esta disciplina y que ha traído una corriente alternativa a las finanzas tradicionales.

Ir en la dirección de poder superar el supuesto de aversión al riesgo de los agentes del mercado, como premisa del modelo de valoración, ayuda a que los mercados financieros se comporten con mayor eficiencia, de acuerdo con estudios anteriores que señalan que considerar el actuar de los agentes puede ocasionar ineficiencias en el mercado (Shiller, 2003) (Sewell, 2007). Esta investigación considera conveniente aplicar la experiencia de probar elementos que den cuenta del comportamiento de los inversionistas en mercados latinoamericanos, dada la escasa existencia de estudios de este tipo en estos mercados, que son pequeños, y muy concentrados frente a otras economías emergentes o ya desarrolladas.

1.2.-Objetivo del trabajo de investigación

El objetivo de la investigación es verificar si el mercado de valores chileno se mantuvo con algún nivel de eficiencia establecida por Eugene Fama, con la irrupción de la pandemia del COVID-19, y contribuir con la búsqueda de variables que puedan incluir el temor de los inversionistas frente a la crisis, tanto en el índice del mercado chileno, como los índices que conforman el MILA (Mercado Integrado Latinoamericano). En este último punto se busca aportar al estudio actual acerca de cómo la ciencia financiera clásica pueda incorporar elementos de las finanzas conductuales, específicamente variables que se obtengan fácilmente y que provengan de información pública, con el fin de incorporar información a los modelos de valoración tradicionales, el actuar de los agentes del mercado financiero frente a esta crisis. Proponiendo finalmente un modelo de valoración basado en el CAPM tradicional de mejor desempeño en pandemia, adicionando factores de riesgo de conducta de los agentes, que permita mejorar el valor de los activos en el mercado financiero de los países sometidos a estudio, en un estado de la economía de emergencia sanitaria.

Objetivos específicos

Se someterá a evaluación al modelo CAPM (Treynor, 1961) (Sharpe W. , 1964) (Lintner, 1965) (Mossin, 1966) y sus variantes más relevantes desde su origen, comenzando con el modelo de un factor, que es el modelo de mayor utilización en el mercado bursátil de Chile. Se busca obtener respuestas a las siguientes interrogantes: ¿Es adecuado que el modelo CAPM de un factor, se continúe

aplicando en la valoración de los activos en este mercado?, ¿Cuál modelo de valoración obtiene mejor rendimiento en este mercado?. Estas respuestas buscan establecer la importancia de evaluar el modelo de valoración antes de su aplicación y utilización de sus resultados.

Se verificará si el mercado de valores de Chile se encuentra en la forma de eficiencia débil propuesto por (Fama, Eugene, 1970), en período antes de pandemia, con el fin de conocer si se cumplen los supuestos teóricos del modelo y de la teoría de finanzas corporativas, respondiendo a las siguientes interrogantes: ¿Es coherente la relación riesgo retorno?, donde a mayor riesgo se obtiene un mayor retorno, ¿Los datos se distribuyen linealmente?, y por último ¿la fuente de riesgo sistémico, es la apropiada para el mercado, en el período examinado?.

Como se indicó anteriormente los mercados desarrollados se comportaron ineficientes financieramente frente a la llegada del COVID-19, es por esta razón que es relevante revisar la forma de eficiencia financiera del mercado chileno, con la irrupción de la pandemia en marzo de 2019 en el país, la interrogante a responder en esta etapa de la investigación es: ¿El mercado chileno actuó de manera eficiente ante la llegada del COVID-19?

Determinación de que modelo de valoración clásico derivados del CAPM, en período sin y con pandemia, para responder la siguiente interrogante: ¿Qué modelo de valoración clásico es de mejor rendimiento en el mercado de valores de Chile, en periodo sin pandemia y con pandemia del COVID-19?, como también la evaluación de los factores de riesgo de mejor desempeño en los períodos analizados.

Evaluación de factores de riesgo exógenos al modelo de valoración, que sean candidatos para incorporar información acerca de cómo reaccionan los agentes del mercado de valores en el período de crisis pandémica, con la finalidad de obtener, que factores son importantes para los mercados en estudio, que puedan ser incorporados en el modelo de valoración de mejor su desempeño en la crisis del COVID-19. Este objetivo responde la siguiente pregunta ¿Cuál o cuáles factores exógenos al modelo de valoración, poseen información relevante, en situación de pandemia?

Con el objetivo de aunar las finanzas tradicionales con elementos de las finanzas conductuales, se propondrá un modelo de valoración que considere el actuar de los inversionistas en tiempo de crisis del COVID-19, conservando el mismo

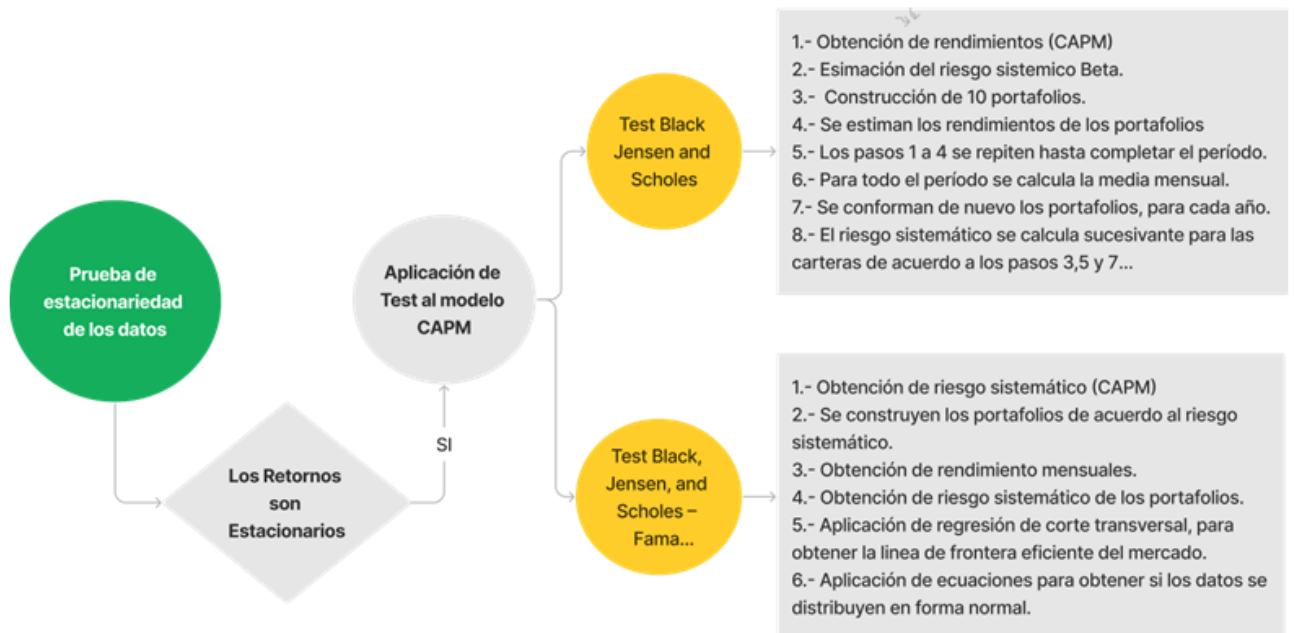
espíritu de los modelos en su simpleza de aplicar con información pública y de fácil acceso por todos.

Se probará la validez de la variable de riesgo que se construyen a partir de intensidad de búsqueda almacenadas en el motor de búsquedas de Google, verificando si este factor clasificado en términos de consulta positivos como negativos, en periodo de crisis sanitaria, da respuesta a la siguiente interrogante: ¿La intensidad de búsquedas de términos asociados al temor en un momento determinado, tiene relación con las acciones que toman los agentes en el mercado en estudio, en la crisis sanitaria?

1.3.-Metodología de la investigación

En el capítulo dos, los elementos de la metodología que se utilizan en la presente investigación se centran en dos aspectos, el primero se utiliza para verificar la forma de eficiencia débil en el mercado de Chile utilizando una prueba de estacionariedad de las series de datos y posteriormente se analiza la validez del modelo de valoración CAPM de un factor de riesgo, es útil mencionar que, una vez comprobada la aleatoriedad de los datos, se somete a estudio el modelo de valoración.

Figura 1.1: Diagrama de metodología utilizada en capítulo 2, Elaboración propia.



En la figura 1.1 se puede apreciar el proceso aplicado para verificación de la forma de eficiencia financiera del mercado y validez de la aplicación del modelo CAPM de un factor, en primer lugar, se comprueba si los retornos de los activos son estacionarios, por medio del test de (Dickey & Fuller, 1979), si los retornos

son estacionarios se pueden aplicar las pruebas al modelo de valoración CAPM de un factor. El test Dickey Fuller es utilizado para comprobar el nivel de eficiencia débil de la información del mercado, por lo que se consideró este test para concluir la forma de eficiencia del mercado en otras investigaciones recientes en mercados emergentes. (Ramírez, Valencia, & Villalba, 2017) (Worthington & Higgs, 2003) (Tokić, Bolfek, & Peša, 2018) (Yasmin, 2022)

Para comprobar la eficiencia del mercado, lo más importante es comprobar si las series de rentabilidad del mercado de valores siguen un camino aleatorio. la prueba de raíz unitaria se usa para verificar si la serie de retorno tiene un patrón o tendencia. Si se encuentra un patrón, la serie de retorno tiene una media, una varianza y una covarianza constantes; en otras palabras, no hay raíz unitaria, por lo que los datos son estacionarios. Si los datos tienen raíz unitaria, significa que los inversores no pueden predecir el futuro empleando estrategias comerciales. (Yasmin, 2022). La estacionariedad da cuenta que las variables no tienen tendencia a crecer a lo largo del tiempo, con frecuencia se da este proceso estacionario en los precios de las acciones, debido a que tienen un comportamiento propios del camino aleatorio, debido a que no hay posibilidades de arbitraje y por consiguiente el precio actual de una acción es igual al precio anterior más un error impredecible, lo que hace que exista un juego justo en el mercado.

El proceso de raíz unitaria consiste en que la variable y_t siga un proceso autorregresivo de primer orden AR(1), es decir que su valor actual depende de su valor anterior más un término de perturbación aleatoria.

Las pruebas de raíces unitarias principales derivadas (Dickey & Fuller, 1979) consisten en la siguiente expresión:

$$y_t = \phi y_t + u_t$$

La ecuación se interpreta de la siguiente forma y_t , sigue un proceso autorregresivo de orden 1 (AR(1)), es decir su valor actual depende de su valor anterior más un término de perturbación aleatoria.

Donde: $u_t \sim RB(0, \sigma_u^2)$

Donde u_t se supone sigue una distribución normal, con media cero y varianza constante, que se conoce como ruido blanco.

Test	Características	Aspectos Para Considerar
DF – Dickey Fuller	Toma como supuesto que la serie se puede aproximar a un proceso autorregresivo de orden uno (AR (1))	No considera la correlación serial de los errores.
ADF - Dickey-Fuller Aumentada	Es una versión modificada de la prueba DF, la cual se puede aplicar para un conjunto más amplio y complejo de modelos de series de tiempo y en la cual no se supone que el término aleatorio de error no esté correlacionado	La prueba de Dickey Fuller aumentada se puede utilizar con correlación serial.
Phillips-Perron	Esta prueba se utiliza en el análisis de series de tiempo para testear la hipótesis nula de que una serie de tiempo es integrada de orden 1, dicho de otro modo, analiza la existencia de evidencia que permita afirmar si la serie sigue una caminata aleatoria.	Al igual que la prueba de ADF, la prueba de Phillips-Perron asume que el proceso de generación de y_t podría seguir un orden superior de autocorrelación que es aprobado en la ecuación de prueba. Una de las ventajas es considerar series no paramétricas, es decir no considera el tipo de distribución de los datos.
Kwiatkowski, Phillips, Smichdt y Shin (KPSS)	La prueba KPSS permite conocer si la serie es fraccionalmente integrada, esto implica que permite probar tanto la hipótesis de la raíz unitaria como la hipótesis de la estacionariedad para una serie de tiempo, por lo cual se pueden distinguir entre series que parecen ser estacionarias, series que parecen tener una raíz unitaria y series que pueden seguir una tendencia estacionaria.	en la prueba KPSS, la hipótesis nula asume que la serie es estacionaria, de este modo, en caso tal de rechazarse, la serie sigue un proceso de caminata aleatoria.

Tabla 1.1: Pruebas de raíz unitaria consideradas. (Dickey & Fuller, 1979) (Phillips & Perron, 1988)

En este capítulo se utiliza la prueba de Dickey Fuller Aumentada, si bien es cierto todas estas pruebas tienen la debilidad de poder obtener el error de tipo I, esto es rechazar la hipótesis nula siendo esta verdadera. Se elige esta prueba ya que considera métodos paramétricos (se utilizará bajo el supuesto de normalidad), por ejemplo, la prueba de Phillips Perron, considera métodos no paramétricos.

Una vez que se revisa que las series de tiempo de los retornos utilizados en el análisis son estacionarias, se está en condiciones favorables para aplicar pruebas al modelo CAPM de un factor.

Para analizar la validez del modelo de valoración CAPM de un factor de riesgo, se crean portafolios con acciones que componen el índice IPSA de la bolsa de valores de Santiago de Chile, los cuales se someten a las siguientes pruebas: regresión en dos etapas, Black, Jensen and Scholes (BJS) (Black, Jensen, & Scholes, 1972), y la prueba de Black, Jensen and Scholes – Fama Macbeth (Fama, Eugene; MacBeth, James, 1973). La prueba a los factores del riesgo del modelo originalmente propuesta por Black, Jensen y Scholes, (BJS) y perfeccionados por Fama y Macbeth, (FM) en su método de contraste a partir de la prueba BJS. La característica más destacada es el uso de carteras en lugar de activos individuales al probar los modelos de valoración de activos. Esto se ha considerado esencial durante mucho tiempo debido a un problema de error en las variables inherente a la estimación de las primas de riesgo, cuando se utilizan activos individuales pueden tener sesgos y agrupados en carteras poseen menos riesgo idiosincrático (riesgo que afecta sólo a un sector económico o industrial).

Los métodos de BJS y FM proponen el siguiente proceso de regresiones de dos pasos:

1. Regresiones de series temporales, compuesta de los retornos de los activos individuales, en el caso de este capítulo, utilizará el modelo CAPM. Con este paso se obtiene el riesgo sistemático (Beta) de los activos.
2. Se realizan regresiones de corte transversal sobre los riesgos sistemáticos obtenidos en el paso anterior.

Con los activos agrupados en portafolios, el problema de error en las variables puede reducirse. Este proceso se realiza ordenando los activos por alguna características, en este caso por el nivel de riesgo sistemático, obtenida en el paso 1, pero esta utilización si bien tiene la ventaja de evitar errores de sesgo (las carteras poseen menos riesgo idiosincrático) en las variables, tiene como desventaja al utilizar las carteras ya que reduce la dimensionalidad. En concreto esto es que hay menos variables explicativas que con los activos individuales. Otro aspecto que se debe tener en cuenta es que, al realizar la agrupación de los activos individuales en carteras, este proceso puede enmascarar fenómenos transversales presenten en activos individuales, por ejemplo, un activo que este sobrevalorado en el mercado, con otros que estén subvalorados al conformar una

cartera, puede que estos errores sean indetectables. (Jegadeesh, Noh, Pukthuanthong, Roll, & Wang, 2019).

La diferencia entre estudios BJS y FM, En BJS, los retornos y riesgo sistemático (beta) se calculan en los mismos períodos. En FM, El riesgo sistemático en un período se utiliza para predecir los rendimientos del período posterior, debido al supuesto que el riesgo obtenido en un periodo t , afecta a los retornos en período $t+1$.

Se comprueban los siguientes aspectos del modelo de valoración en ambos test:

1. Si el intercepto es igual a cero, este intercepto corresponde al activo libre de riesgo utilizado.
2. El supuesto de aversión al riesgo, que consiste en que a mayor riesgo el inversionista exigirá un mayor retorno.
3. Relación lineal entre retorno esperado y riesgo.
4. Sólo β_i , (riesgo sistemático) afecta a los rendimientos del activo i , no existe otro riesgo del sistema que está inserto el activo que afecte el precio de los activos.

En el capítulo 3, que se encarga de la revisión de eficiencia del mercado con la llegada del COVID-19, se utiliza la metodología de estudio de eventos, por industria en el mercado de valores chileno.

Figura 1.2: Diagrama del proceso metodológico aplicado en el capítulo 3, elaboración propia.



En la figura 1.2, se aprecia el proceso metodológico que se aplica en el capítulo: en primer lugar, se debe fijar la fecha del evento que se analizará, en este caso es. El día $t=0$ es el día 03 de marzo de 2020, que corresponde al primer caso de COVID-19 en Chile. Los resultados se presentan para una ventana de $[-10;+10]$ días en torno al primer caso de COVID-19 en Chile, se definen 10 días antes y diez días después, más el día del evento, comprende 21 días que equivale en promedio de los días hábiles de negociación en un mes de operaciones, no obstante, el análisis se realizó para un período de 424 días entre julio de 2019 a septiembre de 2020.

Se debe considerar que un estudio de eventos se basa en el supuesto de la hipótesis de mercado eficiente de (Fama, Eugene, 1970), esto significa que cualquier evento en el mercado se puede reflejar inmediatamente en los precios de los activos del mercado financiero, lo que explica el efecto de la divulgación de información sobre los rendimientos de las acciones y la reacción esencial, porque las evaluaciones y expectativas de los inversionistas financieros se ven afectadas por anuncios o eventos y reflejados finalmente en el precio de los activos. Con base en el supuesto de racionalidad de los mercados financieros, esta metodología de estudio de eventos se emplea ampliamente para medir el efecto de un evento en un los rendimientos de las acciones de la empresa y capturar las reacciones a los informes y eventos que pueden afectar al mercado. (Ji, y otros, 2022) (Binder, 1998), en finanzas el estudio de eventos es el más utilizado, aumentando su uso para el estudio de la irrupción de la pandemia en los mercados (Ghoul, Guedhami, Mansi, & Sy, 2022).

Para obtener los rendimientos acumulados (AR) y los rendimientos anormales acumulados (CAR), se utilizan tres modelos para evaluar el mercado en crisis sanitaria: modelo de rendimiento promedio ajustado (MRPA), modelo de rendimiento de mercado ajustado (MRMA) y el modelo de mercado (MM). Posteriormente se analizará la normalidad de los datos del periodo en estudio, para conocer la distribución de los datos, necesario, ya que un supuesto del modelo de valoración es que los retornos tienen una distribución normal

El modelo de rentabilidad media ajustada (MRMA) supone que la rentabilidad ex ante normal del activo i es equivalente a la rentabilidad media diaria de las acciones estimadas, que puede variar entre poblaciones. El rendimiento anormal, AR, es el mismo después de deducir el rendimiento normal, R_t , del rendimiento actual observado.

El modelo de rendimiento promedio ajustado (MRPA), es un modelo más simple que se basa en el modelo anterior (MRMA), donde se supone que el rendimiento estimado del activo estudiado es igual al rendimiento del mercado; por lo tanto, el modelo expresa que $\hat{\alpha}_i = 0$ and $\hat{\beta}_i = 1$, dado que alfa es casi consistentemente una cifra menor y el promedio beta (riesgo sistemático)

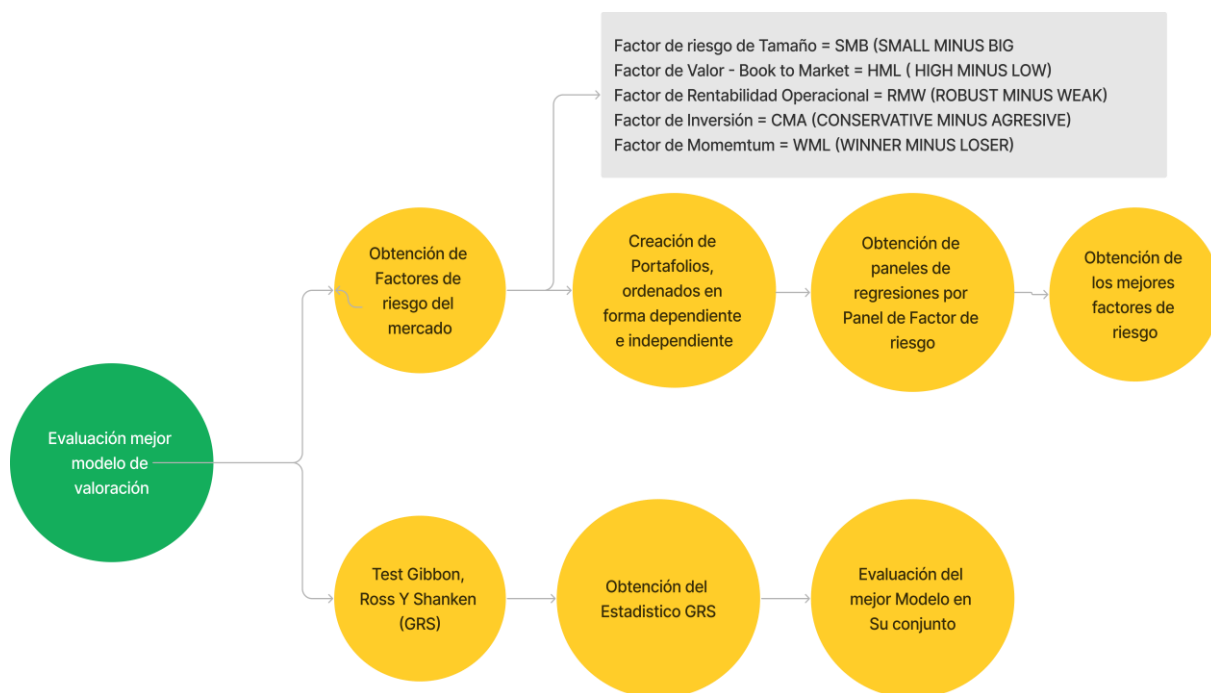
El Modelo de mercado (MM), considera todas las variables de mercado y el riesgo sistemático de cada activo. Este modelo de retorno de un factor fue desarrollado por Sharpe (Sharpe 1963).

Con estos métodos se calculan los retornos anormales y luego con la sumatoria de la ventana establecida se obtienen los retornos anormales acumulados.

Lo que busca dar respuesta el proceso metodológico del capítulo 3 es lo siguiente: como actúa el mercado chileno frente a la llegada del COVID-19, por industrias que componen el índice IPSA. Además, por medio de la revisión de la distribución de los datos se verificará si cumplen con el supuesto de distribución normal de los retornos en que se basa el modelo de valoración CAPM.

En el capítulo 4, se encarga de elegir el modelo de valoración de mejor desempeño en el período de crisis sanitaria, donde se revisan los siguientes modelos: CAPM de un factor y los modelos de Fama French de tres factores (FF3F), de Fama Cahart de cuatro factores (FC4F) y Fama French de cinco factores (FF5F).

Figura 1.3: Proceso metodológico para la obtención de mejores factores de riesgo y modelo de valoración en general, elaboración propia.



Se utilizarán dos períodos para la prueba empírica, uno con crisis sanitaria y otro sin pandemia. El periodo completo para analizar es entre 2007 y 2021, donde el periodo con pandemia se establece a partir del 1 de enero de 2019, para el mercado chileno.

Para la obtención de los factores de riesgo del mercado se realizará el siguiente proceso, que se muestra en la figura 1.3:

Obtención del tamaño bursátil (precio de la acción por cantidad en circulación) de cada empresa listada en el índice IPSA, por cada año sometido a estudio, luego se obtiene el promedio para ambos períodos sometidos a estudio por empresa, separándolas en pequeñas y grandes. Para el ratio valor (Book to Market) se obtienen para cada año el valor contable del patrimonio de cada empresa al final de cada año fiscal y el valor bursátil a la misma fecha, luego se promedian los resultados obtenidos, para los periodos sometidos a estudio. Para el factor de riesgo de rentabilidad operacional, se extrae la información desde los estados financieros de cada empresa y se obtiene el promedio para ambos períodos de estudio. Con respecto a la obtención del factor de inversión se obtiene el monto de cada empresa desde los estados financieros anuales, promediando por cada empresa en ambos períodos y finalmente para el factor momentum, se obtienen los retornos mensuales por cada empresa y se promedian de acuerdo a los

periodos de estudio. Con todo este proceso se separan las empresas por los factores antes indicados, para someter a revisión de los modelos y factores.

El modelo de valoración CAPM, fue evidenciando en el tiempo, que el riesgo sistemático no explicaba los retornos en el largo plazo, en mercados desarrollados, a partir de esta problemática (Fama, Eugene; French, Kenneth, 1993), introdujeron el factor tamaño SMB (Small Minus Big) y valor HML (High Minus Low), como corrección, encontrando que mejora la predicción del modelo. Este hallazgo se fundamenta en que las empresas más pequeñas, denominado como "small firm effect", obtienen mayor rentabilidad que las empresas grandes, bajo el supuesto que las empresas pequeñas tienen mayores oportunidades de crecimiento, lo que hace que logren mayores retornos que las empresas más consolidadas en el mercado, con respecto al ratio de valor (Book to Market) HML (High Minus Low), tuvieron como hallazgo que las empresa con alto ratio, tienen mayores retornos que las empresas con baja relación valor libro y valor de mercado, bajo el supuesto de que las empresas que tienen alto ratio, estarían infravaloradas por el mercado, ya que su valor libro es mayor al valor bursátil y por esta razón obtendrían mayores recompensas a futuro cuando en el mercado se corrija su precio. Posteriormente al evidenciar falta de factores de riesgo (Fama & French, 2015), agregaron dos factores más, proponiendo el modelo de Fama y French de cinco factores. Incluyen los factores de rentabilidad operacional RMW (Robust minus Weak), bajo la lógica que las empresas que presentan mayor rentabilidad operacional obtienen mayores retornos de aquellas que tienen menor rentabilidad operacional y el factor de inversión CMA (Conservative minus Agresive), bajo la premisa que las empresas más conservadores en inversión obtienen mayores retornos en el corto plazo, que las empresas que más invierten. Anteriormente (Carhart, 1997) agrega un factor de riesgo al modelo de Fama y French de tres factores, que es el factor de Momentum WML (Winner minus Loser), que representa la diferencia entre los retornos de las empresas ganadoras y perdedoras en el periodo de estudio.

Existe una investigación de (Novy-Marx, Robert, 2012) donde identifican que el proxy de rentabilidad operacional (RMW) está estrechamente vinculado con los retornos promedios de los activos. Para estos investigadores el factor valor HML de una empresa es una especie de efecto de apalancamiento. Las estrategias de "valor" son la financiación de los activos infravalorados mediante la venta de activos sobrevalorados. Además (Novy-Marx, 2013) consideran que las estrategias basadas en financiar la adquisición de activos productivos vendiendo

activos poco productivos, está estrechamente relacionada y explican parcialmente al factor de rentabilidad operacional, por esta razón Fama y French consideran que el factor valor (HML) resulta redundante cuando se agrega la rentabilidad operacional en el modelo.

Lo que busca dar respuesta el proceso metodológico del capítulo 4 es: revisar los factores de riesgo más importantes del modelo CAPM, en el mercado chileno en dos periodos, sin pandemia y con pandemia del COVID-19. La importancia de esta etapa en la investigación es revisar los factores de riesgo endógenos más importantes (con mayor significancia estadística) y ampliamente utilizados tanto para investigaciones, como la industria financiera. Además, se prueba que modelo en su conjunto tiene mayor rendimiento en ambos periodos propuestos en la investigación. Para conseguir el modelo de valoración de mejor rendimiento se aplicará el estadístico GRS, para obtener el modelo de mejor desempeño. La prueba del modelo consiste en determinar si todos los alfas (interceptos) son conjuntamente cero. Teniendo en cuenta que todas las regresiones efectuadas para cada portafolio han generado distintos alfas. (Gibbons, Ross, & Shanken, 1989). Los investigadores han utilizado una gran variedad de pruebas para determinar si las intersecciones en un conjunto de regresiones de series de tiempo son todas igual a cero. Las pruebas tienen las mismas propiedades asintóticas, pero existe una controversia sobre cuál posee mejores propiedades en muestras pequeñas.

Este test GRS es utilizado por (Fama, Eugene; French, Kenneth, 1993) (Fama & French, 2015) y otros investigadores para evaluar la capacidad predictiva de los modelos en su conjunto en la valoración de activos. Además, resuelve la controversia proporcionando una prueba F en las intersecciones que tiene propiedades exactas en muestras pequeñas. El estadístico de (Gibbons, Ross, & Shanken, 1989), prueba si el proxy del mercado es la tangencia de la cartera en el conjunto que se pueden construir combinando las carteras con los activos específicos, utilizados como variables dependientes en la regresión de la serie temporal. (Fama, Eugene F.; French, Kenneth R., 2004)

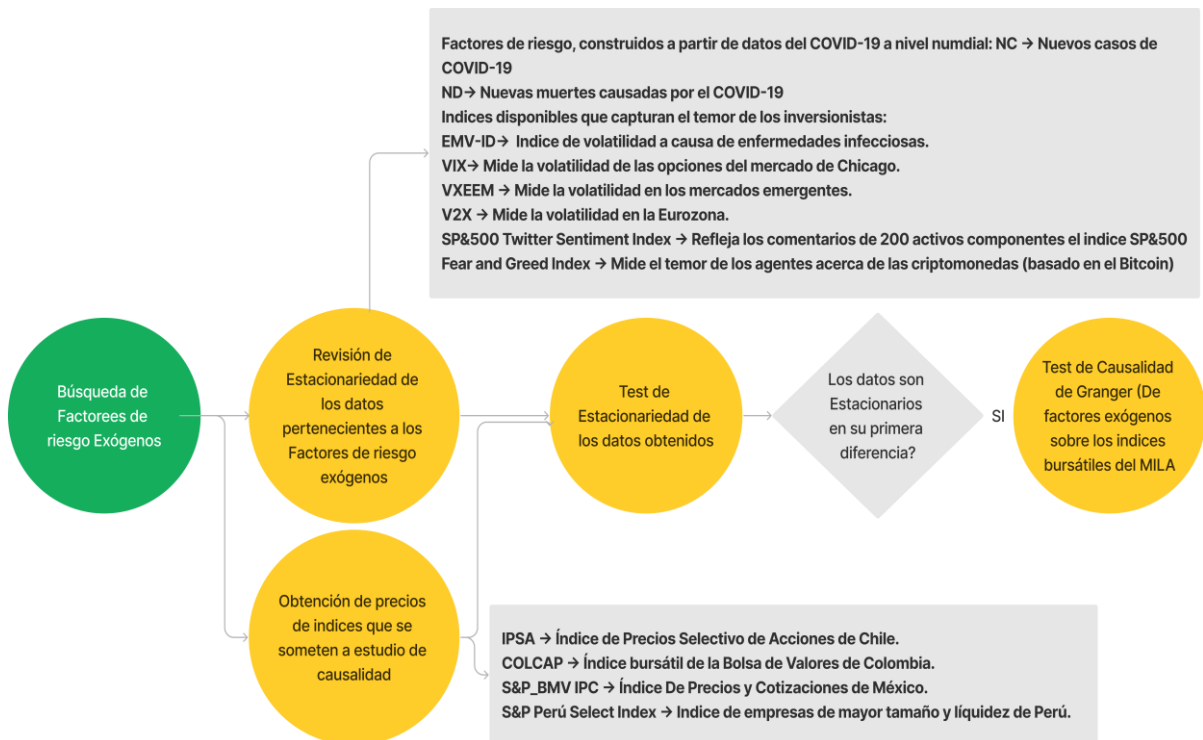
El hecho de no rechazar la hipótesis nula del test GRS representa evidencia estadística de que el modelo captura adecuadamente la variación sistemática de los rendimientos de activos o carteras. Sin embargo, muchos estudios anteriores informan que la prueba GRS no puede aceptar la hipótesis nula para un rango de modelos de precios de activos en el nivel convencional de significancia de 5% (Kim & Shamsuddin, 2017) (Fama, Eugene; French, Kenneth, 1993) (Fama &

French, 2015). En la prueba de hipótesis, es una convención establecer el valor de α en 5%, aunque a menudo se usan otros niveles como 1% o 10%. Sin embargo, estos niveles convencionales son arbitrarios. En la prueba de hipótesis, es una convención establecer el valor de α en 5%, aunque otros niveles entre 1% a 10% se utilizan a menudo. Debido a al problema indicado de la prueba GRS en esta tesis se utilizará nivel de significancia del 10%.

El capítulo 4, aporta a los objetivos, encargándose de buscar que modelo de valoración derivado del original CAPM es de mejor desempeño en periodo sin pandemia, como en periodo de pandemia de COVID-19.

El proceso metodológico del capítulo 5, para la búsqueda de factores de riesgo que aporten a mejorar el rendimiento de los modelos de valoración. Se prueban tres tipos de factores, acerca del comportamiento de los inversionistas. Específicamente se utilizarán índices de volatilidad (VIX), de comentarios en la red social Twitter, a través del índice: SP&500 Twitter Sentiment, del temor y codicia en el mercado de las criptomonedas Fear and Greed Index (FG), además de índices creados en esta investigación a partir de los datos de nuevos casos confirmados y muertes ocasionadas a nivel mundial por la pandemia del COVID-19.

Figura 1.4: Proceso metodológico para la comprobación de factores exógenos que ayuden a la valoración de activos en el MILA (Mercado Integrado Latinoamericano), Elaboración propia.



En la figura 1.4, se muestra el proceso aplicado: El primer paso se aplica para que este estudio tenga consistencia estadística, primero se revisa que los valores de los factores y precios de índices del MILA en su primera diferencia sean estacionarios, para garantizar que los datos no varían en función del tiempo y no tengan tendencia que pueden influir en el error en la estimación y predicción de los modelos de valoración. Si las series de tiempo son estacionarias en su primera diferencia se evalúa la causalidad de los factores de riesgo ante mencionados con los índices bursátiles que componen el Mercado Integrado Latino Americano (MILA), este proceso econométrico, utiliza el modelo de autorregresión vectorial (VAR) y la causalidad de Granger (Capacidad de predicción) (Granger, 1969). La prueba de causalidad consiste en cuantificar si la variable X causa a la variable Y, esto implica que existe información relevante en X y que no está considerada en los datos históricos de Y. Una de las principales desventajas es limitar el análisis a aplicaciones bivariados, lo que puede dejar de lado causalidad directa en conjuntos de datos. Otra de las desventajas es la alta sensibilidad de la prueba al tiempo, si los datos están contenidos en submuestras es probable que las series de tiempo presente perdidas en causalidad entre las variables. (Danks & Plis, 2013) (Hyttinen, Plis, Järvisalo, Eberhardt, & Danks, 2017). Finalmente, la desventaja que tiene el proceso de causalidad es que al ser un modelo puramente matemático no es posible obtener una explicación de la causalidad. El otro aspecto debilidad del proceso econométrico es que no es capaz de distinguir el comportamiento de más de dos series temporales, si bien es cierto esta desventaja ha sido abordada hoy en día por procesos matemáticos más complejos apoyados con procesamiento computacional (Runge, Nowack, Kretschmer, Flaxman, & Sejdinovic, 2019), no se será aplicada en este trabajo de investigación.

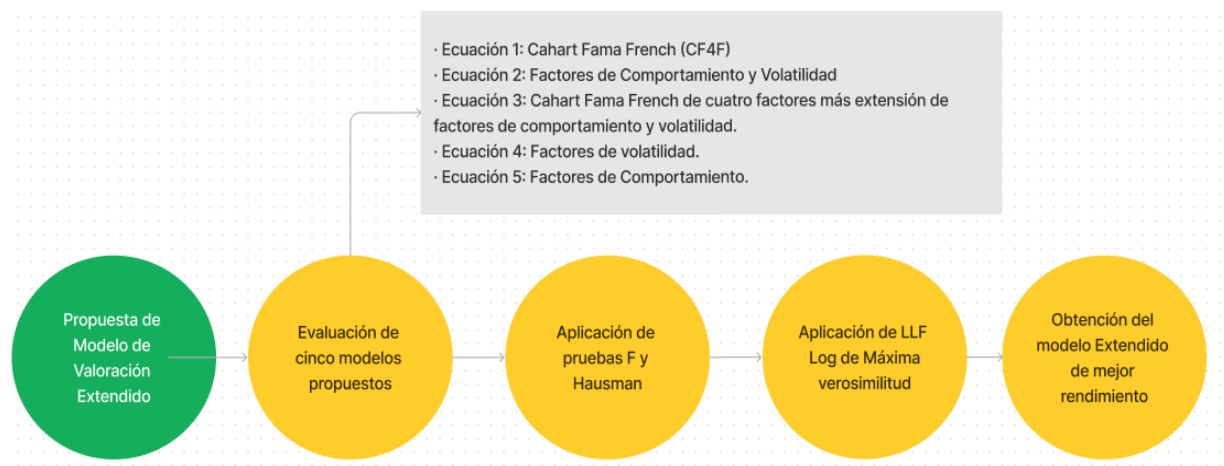
Lo que se busca con este proceso es obtener que factores exógenos al modelo y que puedan entregar información relevante acerca del actuar de los agentes del mercado, acerca de los índices que componen el MILA en tiempo de crisis sanitaria.

El capítulo 5, se encarga de obtener los factores de volatilidad, factores de comentarios acerca del índice SP&500, que capturan el sentimiento de los inversionistas, del miedo que captura el temor del mercado de las criptomonedas (específicamente del Bitcoin), y variables creadas en esta investigación a partir de datos mundiales del COVID-19, como son los nuevos casos confirmados y cantidad de muertes a causa de la pandemia. Los factores de riesgo revisados

pasarán a formar parte del modelo extendido, adicionando el comportamiento de los agentes del mercado que busca este estudio.

El capítulo 6, la metodología utilizada se aplica para obtener un modelo de valoración extendido a partir de los modelos tradicionales, agregando factores de riesgo exógenos que aporten a la información que corresponde al sentir de los inversionistas. Una vez que se prueba causalidad de los factores de riesgo, aquellos que muestren causalidad estadística con los índices del MILA, formarán parte del modelo de valoración propuesto por esta investigación en tiempos de crisis pandémica.

Figura 1.5 Proceso metodológico para probar el modelo extendido con factores de riesgo exógenos, Elaboración propia.



En la figura 1.5, muestra el proceso metodológico para poner a prueba un modelo de valor basado en el tradicional agregando factores de riesgo exógenos, de volatilidad, sentir del agentes por medio de búsquedas en Google, del miedo a través del índice que captura este sentir desde el Bitcoin e índices creados en esta investigación con datos mundiales de la pandemia (muertes y nuevos casos). En primer lugar, se evalúa el modelo de mejor desempeño, extendido del modelo clásico, posteriormente se plantea un modelo de comportamiento y volatilidad, compuesto con solo factores exógenos, como un modelo con los factores clásicos y exógenos, luego un modelo que cuente con sólo factores de riesgo de volatilidad y por último un modelo que incorpore los factores de comportamiento. Luego estos modelos se le aplican las pruebas específicas para datos de panel, propuestos en este capítulo, por medio de regresiones de panel y pruebas F y de Hausman, para evaluar el rendimiento en los índices que componen el Mercado Integrado Latino Americano (MILA).

El estadístico F es una prueba que se utiliza para evaluar la capacidad explicativa que tiene un grupo de variables independientes sobre la variación de la variable dependiente del modelo sometido a evaluación. Y el Test Hausman (Hausman, 1978), que puede ser interpretado como un test de validez del estimador de efectos aleatorios. Esta prueba consiste en obtener un estimador de efectos fijos es siempre consistente y el estimador de efectos aleatorios sólo lo es cuando las variables explicativas no están correlacionadas con el término aleatorio. En este sentido, el test de Hausman realiza una prueba de exogeneidad de las variables explicativas con respecto al efecto aleatorio. Si se rechaza la hipótesis de exogeneidad de los regresores entonces, el test estaría sugiriendo que el estimador de efectos aleatorios es inconsistente y por tanto convendría utilizar el estimador de efectos fijos que seguiría siendo consistente aún en presencia de dicha correlación. (Gómez Jacinto, 2014)

Para someter a las variables exógenas a revisión de su aporte a la variable dependiente en este caso los índices que componen el MILA, se utilizará el estimador de máxima verosimilitud Log-verosimilitud. Este modelo Logit estima la probabilidad de impacto de las variables explicativas sobre la variable dependiente que en este caso es de respuesta cualitativa. Se calcula la función de log verisimilitud, esta función nos permite comparar modelos, donde dos modelos en el que en uno de ellos se incluye una variable adicional con respecto al primer modelo (correspondiendo a las variables de comportamiento de los agentes en la investigación). Esta función se distribuye como chi-cuadrado con grados de libertad igual a la diferencia de parámetros entre modelos, que este caso es un grado de libertad. Se le denomina contraste de verosimilitud. Si el contraste resulta ser no significativo se acepta que la incorporación de la nueva variable no mejora sensiblemente la verosimilitud del modelo y por tanto no es necesario incorporarla al modelo sometido a análisis. (Gómez-Mejía, 2020).

El mejor modelo es el que hace que los datos sean más probables, o maximiza la función de verosimilitud: $f_n(X_{t-1}, \dots, X_n | \beta)$

La hipótesis H_0 : indica que el modelo más pequeño es mejor (Modelo en términos de variables explicativas). Rechazar la hipótesis nula indica que el modelo con más variables explicativas es mejor o mejora la explicación de la variable dependiente que el modelo que contiene menos variables explicativas.

Este capítulo se encarga de proponer un modelo de valoración extendido con factores de riesgo exógenos que aporte información del comportamiento de los agentes del mercado en situación de crisis de la pandemia del COVID-19.

En el capítulo 7, el proceso de búsqueda de factores de comportamiento se encarga de estudiar elementos que provienen desde la revolución de los datos (Big Data).

Figura 1.6: Proceso metodológico del proceso de prueba de términos de búsquedas de Google, que pueden ser predictores de los índices bursátiles que componen el MILA, elaboración propia.



En la figura 1.7, muestra el proceso metodológico del capítulo, comienza con la obtención de una base de términos extraídos desde la investigación de (Preis, Moat y Stanley 2013), agregando términos del COVID-19 y adaptación de otros términos locales de los países que componen el MILA. Para obtener la intensidad de consultas en el motor de búsquedas de Google de cada uno de los términos de la base de datos adaptada, que permitan aportar información acerca del temor o sentir del inversor en un momento determinado, en este caso con la crisis del COVID-19, luego se obtienen datos de cada termino desde la plataforma Google Trends, para el período en estudio. Estos datos se deben someter a consistencia estadística, y esta tarea se realizará por medio de regresión LASSO (Tibshirani,

1996), para verificar qué vocablo puede convertirse en predictor de los índices que componen el MILA.

LASSO (Least Absolute Shrinkage and Selection Operator) es una técnica de regresión lineal regularizada que aplica una penalización a la suma del valor absoluto de los coeficientes de regresión ($\|\beta\|_1 = \sum_{j=1}^p |\beta_j|$). A esta penalización se le conoce como L_1 y tiene el efecto de forzar a que los coeficientes de los predictores tiendan a cero. Debido a que una variable predictora con coeficiente igual a cero no tiene influencia en el modelo, este proceso logra excluir los predictores menos relevantes. El grado de penalización está representado por el parámetro λ . Cuando $\lambda=0$ el resultado es equivalente al de un modelo lineal por mínimos cuadrados ordinarios. A medida que λ aumenta, mayor es la penalización y más predictores quedan excluidos, la ecuación general es la siguiente:

$$\sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij})^2 + \lambda \sum_{j=1}^p |\beta_j| = \text{Suma residuos cuadrados} + \lambda \sum_{j=1}^p |\beta_j|$$

Existe otra técnica para realizar este proceso de penalización de posibles predictores como la regresión RIDGE (Hoerl & Kennard, 1970), la principal ventaja de LASSO sobre RIDGE es que LASSO, consigue que algunos de los coeficientes sean exactamente cero, mientras que RIDGE no llega a excluir ninguno. Esto supone una relevante ventaja de LASSO en situaciones donde no todos los predictores son relevantes para el modelo y se quiere que los menos influyentes queden excluidos. Otra ventaja que posee LASSO es que cuando existen predictores altamente correlacionados entre ellos, RIDGE reduce la influencia de todos, en cambio LASSO tiende a seleccionar uno de ellos. Existe otro procedimiento denominado Elastic Net, que combina ambas propiedades de penalización de LASSO y RIDGE, sin embargo, en esta investigación se realizará el proceso por medio del proceso de la regresión LASSO, debido a que, si se encuentran correlacionadas las variables de volatilidad, comportamiento o de sentimiento de los inversionistas, es útil que deje una las variables correlacionadas, como candidata a convertirse en un predictor del modelo. (Zou & Hastie, 2005).

1.4.- Resultados.

Los resultados que se obtienen en esta tesis son los siguientes:

En la revisión de la forma de eficiencia financiera débil y sometimiento a prueba del modelo CAPM de un factor se obtienen los siguientes resultados (Capítulo 2):

En la aplicación de prueba de estacionariedad de Dickey Fuller Aumentada en periodo 2007 en el mercado de valores de Chile, obtiene que los retornos son estacionarios. La importancia de que las series sean estacionarias radica en la que los retornos se comportan de acuerdo a la información pasada con una determinada media y varianza, esto permite poder realizar pruebas de regresiones lineales mediante el método de mínimos cuadrados ordinarios (MCO). Bajo este resultado podemos decir que en el mercado chileno se comprueba la eficiencia en su forma débil de Fama y French.

En el proceso aplicado para validar el modelo CAPM de un factor, en el mercado chileno entre 2007 a 2017, se obtienen los siguientes resultados: el intercepto no es igual a cero, el cual en este caso no corresponde al bono anual del banco central en UF (unidad de fomento), en el proceso de revisión es el que mejor se ajusta para la revisión de las series mensuales de los retornos en los años estudiados, además no se cumple la relación positiva entre riesgo retorno, que es la exigencia de mayor retorno en presencia de mayor riesgo. Con respecto al riesgo que captura el modelo, presenta baja explicación a los rendimientos del mercado, esto indica que faltan factores de riesgo que afectan a este mercado en el modelo aplicado. La relevancia de someter a revisión el modelo CAPM de un factor, es la utilización por medio de analistas financieros para valorar y pronosticar precios de las acciones. Este trabajo de investigación sugiere que es importante someter a análisis los modelos de valoración antes de su utilización en un mercado en particular.

En el capítulo 3, que analiza la eficiencia financiera del mercado de valores chileno, se obtienen los siguientes resultados:

Para el este análisis se establecen 10 días antes del evento y 10 días después del evento, fijado como la llegada del COVID-19 a Chile.

La obtención de rendimientos con el método MRMA (Modelo de rendimiento medio ajustado), obtiene el siguiente resultado: el día del evento, los rendimientos anormales de las industrias que conforman el IPSA aumentan

luego de las caídas de los días anteriores (-3 y -1), continúan aumentando hasta el día 3, y luego comienzan a disminuir a partir del día 4 hasta el día 10, mientras que los rendimientos anormales acumulados disminuyen continuamente hasta el día del evento (día 0), luego aumentan hasta el día 4 y finalmente continúan disminuyendo, posterior al evento.

Analizando los resultados con el método MRPA (Modelo de rendimiento de mercado ajustado), las rentabilidades anormales son negativas el día -10, positivas entre los días -9 y -7 (similares a las rentabilidades anormales acumuladas obtenidas), y luego permanecen negativas hasta el día del evento (día 0). Sin embargo, los rendimientos anormales del día 1 al día 4 son positivos y luego se vuelven negativos del día 5 al 10, mientras que los rendimientos anormales acumulados del día 4 siguen siendo negativos.

Los resultados obtenidos con el método MM (Modelo de mercado), son los siguientes: tanto los rendimientos anormales como los rendimientos anormales acumulados son negativos hasta el día -4. Las rentabilidades anormales siguen siendo positivas hasta el día del evento (día 0), pero solo vuelven a ser positivas los días 6 y 10. Sin embargo, las rentabilidades anormales acumuladas son siempre negativas.

En el análisis del mercado chileno en período de pandemia, la aplicación de test de normalidad aplicado a los datos indica que éstos no se distribuyen normalmente, como la mayoría de las series financieras obtienen un forma leptocúrticas. Este tipo de distribución provoca el riesgo de cola, no cumpliendo con el supuesto de normalidad en los datos, en los métodos utilizados en el análisis econométricos de las series de datos financieras, este riesgo puede ocasionar errores en las estimaciones (subestimación / sobreestimación) y proyecciones en el mercado.

Se utilizaron pruebas paramétricas y no paramétricas para examinar, si la llegada del COVID-19 a Chile generó mayores rendimientos irregulares, tanto positivos como negativos, por lo que el estadístico t variará significativamente de 0. Se obtiene como resultado que, con la llegada de la pandemia, el mercado chileno generó mayores rendimientos irregulares, tanto positivos como negativos. El mercado a través del modelo de mercado aplica, es que todas las industrias que componen el índice IPSA poseen un desempeño promedio negativo en sus retornos.

Los resultados de la prueba de rangos con signo indican que no existen diferencias significativas en los datos de rendimientos anormales de las industrias obtenidos por los modelos MRMA (Modelo de rendimiento de mercado ajustado) y MRPA (Modelo de rendimiento medio ajustado) en la ventana previa al evento, el día del evento y después del evento. Diferencias significativas en los retornos anormales solo se obtuvieron por el método MM (Modelo de Mercado). Esto sugiere que los retornos anormales se vieron afectados por las noticias de la pandemia en las ventanas antes y después del evento.

Los sectores financieros (Banca) y de servicios públicos estuvieron menos expuestos a un colapso de la rentabilidad en la crisis de la pandemia. Esta información es útil para el desarrollo de estrategias de inversión durante una emergencia sanitaria.

En el capítulo 4, que tiene como objetivo la revisión de modelos de valoración basadas en el CAPM, se obtienen los siguientes resultados:

El resultado de revisión de los factores de riesgo de los modelos de valoración de Fama y French y sus variantes analizados en un periodo entre 2007 y 2021, con los activos que componen el índice IPSA se obtienen los siguientes resultados:

los factores de premio por riesgo (RM-RF) y de tamaño (SMB), son los factores que presentan mayor significancia estadística en este mercado, sobresaliendo el factor tamaño, en menor proporción obtienen significancia estadísticas los factores de valor (HML) y momentum (WML), y finalmente los factores de rentabilidad operacional (RMW) y de inversión (CMA), son menos relevantes en términos estadísticos en el período analizado.

El resultado de aplicar la prueba GRS, los portafolios ordenados en forma independiente el modelo de Fama Cahart de cuatro factores obtienen el mejor desempeño, también este modelo obtiene el menor intercepto absoluto en portafolios ordenados por los factores de inversión y momentum, y con respecto al factor valor los modelos que obtienen mejor desempeño, son los modelos de tres, cuatro y cinco factores. Con respecto al estadístico coeficiente de determinación (R^2) en ordenamiento independiente, el modelo de Fama Cahart obtiene el mayor coeficiente de determinación en el ordenamiento del factor de inversión y momentum. Con respecto al ordenamiento del factor valor, obtienen

tres modelos el mayor coeficiente de determinación, de tres factores, cuatro factores y cinco factores.

Los portafolios ordenados de forma dependientes, el menor estadístico GRS lo obtiene también el modelo de Fama Cahart de cuatro factores. Sin embargo, en este caso ninguno obtiene significancia estadística, pero en el período sin pandemia, si lo obtienen tres ordenamientos. El menor intercepto absoluto, también lo obtiene en todos los ordenamientos, lo obtiene el modelo modificado por Cahart. El coeficiente de determinación R^2 , en ordenamiento dependiente, solo en portafolios del factor momentum obtiene el mayor coeficiente el modelo de Fama Cahart de cuatro factores, en los demás ordenamientos lo obtiene el modelo de Fama French de cinco factores.

En el capítulo 5, de revisión de factores de volatilidad, del miedo y codicia, como también la revisión factores construidos con información de la pandemia se obtienen los siguientes resultados:

Los resultados de las series datos de índices que corresponden a los índices que componen el MILA (Mercado Integrado Latinoamericano) IPSA de Chile, COLCAP de Colombia, SP BMV IPC de México y SP_PERU_SELECT de Perú, en periodo de pandemia en la región estudiada (marzo de 2020 al 20 de mayo de 2021). Los resultados de los estadísticos descriptivos de estas series de datos, dos índices obtienen promedios positivos (SP BMV IPC y SP PERU SELECT), y dos índices obtienen promedios negativos (IPSA y COLCAP), con respecto a los índices que presentan mayor volatilidad en el período son: IPSA y COLCAP. El estadístico de asimetría de los índices es negativo esto significa que los datos tienen un sesgo negativo, y revisando al curtosis están muy concentrados a la media de la distribución. Finalmente, el estadístico de Jarque Bera indica que la distribución es leptocúrtica, indicando que los datos difieren de una distribución normal.

De acuerdo del análisis gráfico, de los índices bursátiles latinoamericanos. El índice construido de nuevos casos presenta una distribución similar a los índices bursátiles, solo el índice V2X presenta una curva más achatada, pero según el estadístico Jarque Bera, también es una distribución leptocúrtica como las demás distribuciones analizadas.

Las series de datos de los índices del MILA a nivel de precios y retornos, y los factores de riesgo construidos a partir de la información de la pandemia del COVID-19, son estacionarias en primera diferencia, en cambio los índices de

volatilidad del mercados (VIX, V2X), y de enfermedades infecciosas resultan estacionarios sin diferencia, por lo tanto, las series de tiempo de los factores exógenos sometidos al estudio no son espurias. Además, se analiza la correlación serial y la presencia de heterocedasticidad, obteniendo la ausencia de autocorrelación serial, salvo el índice SP BMV IPC (México), la serie de tiempo además presenta heterocedasticidad, estos datos pueden ser modelados por modelos ARCH y GARCH.

En la aplicación de la prueba de causalidad de Granger, se obtienen como resultado que los índices de volatilidad tanto VIX como V2X, presentan significancia estadística y causalidad con todos los índices del MILA al igual que factor de miedo y codicia en el mercado de las criptomonedas. El índice de sentimientos de los inversores capturados por la red social Twitter, presenta causalidad con significancia estadística en los índices de las bolsas de valores de Chile, Colombia y Perú. Con respecto al factor de riesgo de nuevos casos de COVID-19 a nivel mundial, tiene causalidad y significancia estadística para los índices de los mercados de Chile, Colombia y México, en el caso de México es el único mercado donde obtiene causalidad el factor construido a partir de las muertes diarias a causa del COVID-19. Finalmente, los índices VIX, V2X, SP&500 Twitter Sentiment, y Fear and Greed y el índice creado a partir de los nuevos casos de COVID-19 a nivel mundial, presentan información relevante en estos mercados y pueden ser utilizados como factores de riesgo en los modelos de valoración de activos.

En el capítulo 6, en la revisión del modelo de Fama Cahart Extendido con factores de riesgo exógenos propuestos en esta investigación, los resultados son:

El índice IPSA, BMV_IPC, COLCAP, SP_PERU SELECT, el rendimiento del índice en el período obtiene un promedio negativo -0,09%. -0,1%, -0,07% y -0,11%, diarias respectivamente, concordante con las dos crisis que componen el período de estudio, revisando la asimetría (Skewness), de las distribuciones de probabilidad, muestra que el índice se encuentra sesgado negativamente, este provocaría una mayor probabilidad de disminución de los rendimientos. El factor tamaño (SMB) obtiene promedio negativo, con asimetría sesgado positivamente lo que indica que tiene mayor probabilidad de aumento del coeficiente, para los índices IPSA y SP_PERU SELECT, en el caso del índice BMV IPC y COLCAP, obtienen asimetría sesgada negativa, con mayor probabilidad a que el coeficiente disminuya. Los demás factores de riesgo (HML, WML, VIX, V2X, NC y FG), obtienen promedios positivos, con probabilidad de aumento

positivo del coeficiente. Por último, el factor SP500 Twitter Sentiment obtienen coeficiente promedio positivo, pero con mayor probabilidad a disminuir. En todos los índices IPSA y BMV IPC. El índice COLCAP, tienen coeficientes promedios positivos, pero con mayor probabilidad de aumento positivo. Finalmente, el índice SP PERU SELECT los factores de VIX, V2X y NC obtienen promedios positivos con probabilidad de aumento positivo y en el factor de WML y FG obtienen promedios negativos con mayor probabilidad de aumento negativo. Con respecto al factor SP500 Twitter Sentiment, en los índices IPSA, BMV IPC, COLCAP obtiene coeficiente promedio positivo, pero con mayor probabilidad de disminuir, en el caso de SP_PERU SELECT, promedio negativo, con mayor probabilidad de disminuir.

Los resultados de las pruebas F y Hausman de cada una de las 5 regresiones de panel para los cuatro índices del MILA en estudios. Los resultados de todos los modelos de regresión muestran que el modelo de efectos aleatorios es el más apropiado para nuestros datos de panel balanceados. Además, la prueba F el p-value es inferior al 5%, lo que sugiere que la regresión combinada y los efectos aleatorios conducen a resultados de ajuste similares, es decir, las variables en su conjunto aportan a la explicación de la variable dependiente.

El modelo propuesto en esta investigación es el denominado: Fama Cahart Extendido (FCE), para la valoración de los índices el MILA en tiempo de crisis sanitaria. Donde se valida con la función LLF (Log verosimilitud) y el criterio de información (AIC), el modelo que mejor se ajusta es el modelo Fama Cahart de cuatro factores con extensión de noticias de redes sociales, factor de miedo de las criptomonedas, de nuevos casos de COVID-19 a nivel mundial y de volatilidad

Para todos los índices en estudio el modelo Fama Cahart de cuatro factores es el mejor que ajusta en el mercado chileno (IPSA), mexicano (BMV IPC), colombiano (COLCAP) y peruano (SP PERU SELECT), con extensión de noticias de redes sociales, factor de miedo de las criptomonedas, de nuevos casos de COVID-19 a nivel mundial y de volatilidad.

En el capítulo 7, en la búsqueda de nuevos factores que puedan capturar el sentimiento de los inversores, utilizando los índices que componen el MILA se obtienen los siguientes resultados:

En el periodo completo, los términos que tienen efecto positivo en el IPSA son: "crédito", "vender", "impuestos", "sequía", "casa", "viaje", "consumir", "cocina", "inversión", y "emprendimiento". "crédito" frecuentemente se puede

asociar a una crisis financiera, pero tiene un efecto positivo hacia el índice, lo que puede implicar que se tengan mayor acceso a crédito por parte de las personas y empresas, en el caso de “vender”, “impuesto” y “sequía”, tienen un impacto positivo en el índice, puede inferirse que son oportunidades que ven las personas y empresas. El término “casa” está directamente relacionado con el crecimiento real del mercado de valores. Los demás términos de búsquedas positivos infieren directamente en el mercado de “inversión” y “emprendimiento” y el resto en el estilo de vida en tiempos de bonanza.

Los términos que afectar negativamente al índice en el periodo completo son: “crisis”, “precio del oro”, “precio del cobre”, “covid”, “AFP”, “acciones”, “bonos”, “bolsa de valores” y “riqueza”, donde los términos son relevantes en relación con aportar rendimiento negativamente al IPSA. El término de la pandemia y “AFP” en Chile son las administradoras de fondos de pensiones, que además de invertir parte de los fondos de trabajadores en el mercado de valores chileno, se han visto en cuestionamiento por lo bajo de las pensiones que están otorgando a los pensionados, los demás términos de búsquedas están asociados directamente al mercado de valores. Con respecto a los términos de México, al igual que Chile, el término “Covid” obtiene coeficiente negativo, con mayor coeficiente obtiene el término “Dinero”. En los términos de Colombia también aparece el término “Covid” al igual que los países anteriores como coeficiente negativo, aparecen términos financieros y de “Petróleo”, por último, Perú da como resultado términos relacionados al estilo de vida, seguridad y financieros. En el caso de Colombia, los términos con coeficiente negativo aparecen términos relacionados con commodities, “Covid” y “Acciones”. Por último, Perú que amplía en gran medida los términos como predictores en el período de crisis que obtienen coeficientes negativos están asociados a finanzas, estilo de vida, problemas sociales y políticos, con respecto a los coeficientes positivos, se encuentran términos de estilo de vida, finanzas, “Energía” y “Medio Ambiente”.

Los aumentos de volatilidad reflejan la caída del precio del IPSA en el periodo analizado, se ve claramente con la llegada del COVID-19 al país, es decir, gran parte de esta volatilidad afecta en forma negativa al mercado de Chile. Lo mismo se presenta el mercado de México, Colombia y Perú.

Los volúmenes de búsqueda en Google (ASVI), como los volúmenes de búsquedas anormales (ASVA), con la base de términos utilizadas en esta investigación, presentan mayor intensidad de cuando arriba el COVID-19 en

Chile, México y Colombia, sin embargo, en Perú no experimenta una mayor intensidad de búsqueda en los términos estudiados

Los resultados de la volatilidad mensual calculada a través de los precios de los índices, la media mayor la obtiene el IPSA y el menor promedio de volatilidad mensual la obtiene el índice BMV IPC, manteniéndose ese patrón de volatilidad en frecuencia anual, con respecto al período definido como de crisis de pandemia y parte del inicio de la guerra de Ucrania y Rusia, aumenta el promedio de volatilidad en todos los índices, como se visualizó gráficamente anteriormente. Revisando los índices de volúmenes de búsquedas anormales en el motor de Google, el índice ASVA local muestra que en periodo completo el promedio mayor lo obtiene el índice IPSA y el menor (negativo) el índice SP Perú Select, en el período de crisis el promedio baja en todos los índices y en tres índices obtienen promedio negativo.

El resultado de las regresiones que revisan la volatilidad obtiene como resultado que el coeficiente de determinación está por sobre el 83%, lo que significa que la volatilidad del mes siguiente es explicada con la volatilidad del mes anterior y el indicador anual en más del 83% en todos los índices estudiados.

El test de Durbin Watson da sospechas de autocorrelación positiva, y al revisar el test de White, rechaza la hipótesis nula en todos los índices, esto significa que la varianza no es constante y homocedástica. Con respecto al período de crisis los estimadores de varianza mensual obtienen todos los índices, significancia estadística y la varianza anual obtienen dos índices significancia estadística, al igual que el período completo el test de Durbin Watson sugiere la existencia de autocorrelación positiva y el Test de White también indica que no existe varianza constante u homocedástica, ahora bien, bajo esta perspectiva los estimadores pueden seguir siendo insesgados, pero pierden eficiencia.

El indicador de volumen de búsqueda anormal local, en sólo tres índices obtienen significancia estadística (IPSA, COLCAP, BMV IPC) y en período de crisis obtienen significancia estadística en el índice de volumen de búsqueda anormal local los índices COLCAP, BMV IPC y SP PERU SELECT. El estimador de volatilidad mensual obtiene significancia estadística y el estimador anual de volatilidad solo lo obtiene el índice IPSA.

Con respecto a los estimadores de volatilidad mensual y anual, los estimadores de volatilidad y el indicador mensual obtiene significancia estadística en todos

los índices del MILA, y volatilidad anual únicamente obtienen significancia estadística el índice IPSA y COLCAP.

Revisando los resultados de la ecuación que agrega el predictor de búsqueda de volúmenes anormales global período completo, el estimador obtiene significancia estadística en dos índices (IPSA, BMV IPC) y en período de crisis solo México (BMV IPC) no obtiene significancia estadística.

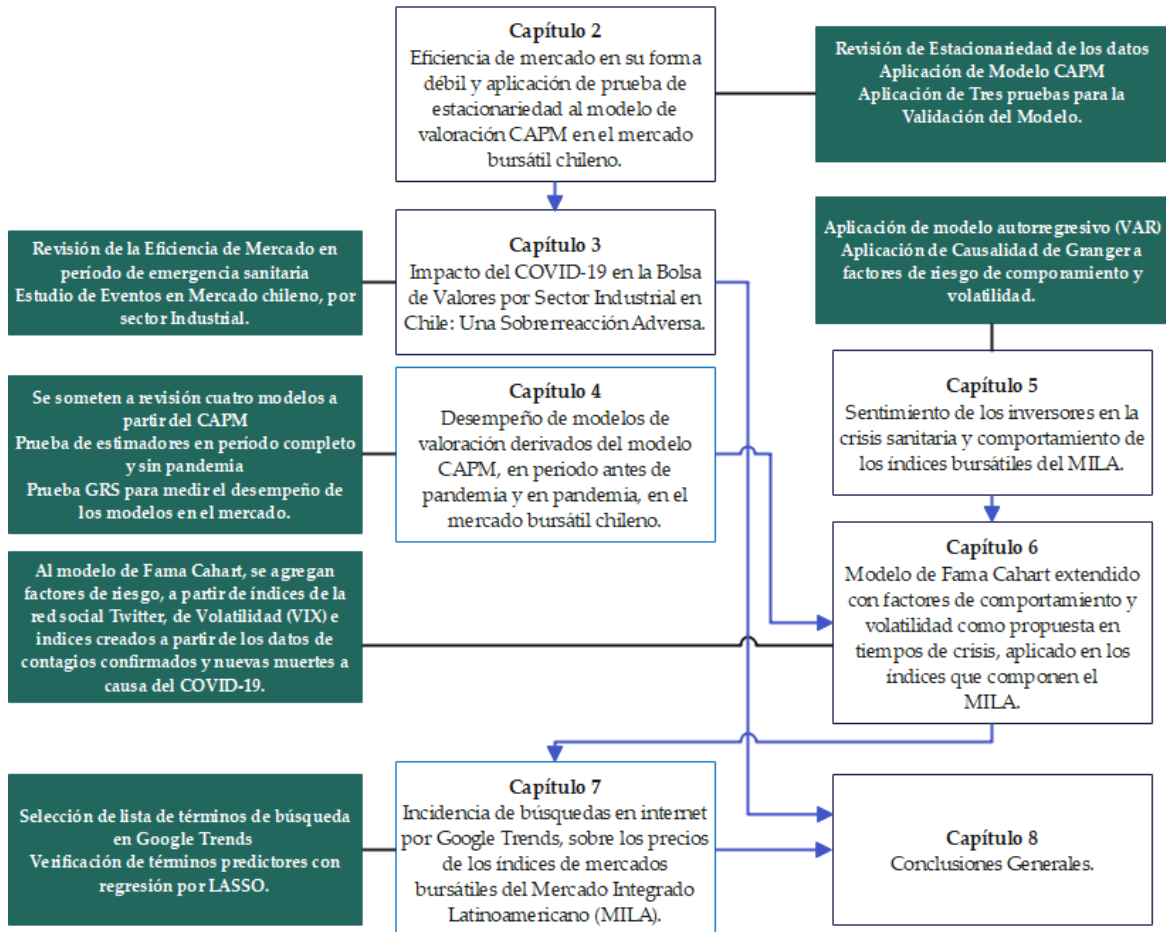
En relación con el período de crisis, verificando los estimadores de volatilidad mensual y anual, mensual obtiene significancia estadística en todos los índices, sin embargo, en volatilidad anual solamente obtienen significancia estadística los índices de Chile (IPSA) y Colombia (COLCAP), y con respecto al predictor de volumen de búsqueda anormal global obtienen significancia estadística los índices IPSA, COLCAP y SP PERU SELECT.

Los estimadores de volatilidad, el indicador mensual obtiene significancia estadística en todos los índices del MILA, y volatilidad anual solo obtienen significancia estadística el índice IPSA y COLCAP.

1.5.-Estructura de los capítulos.

Para llevar a cabo el propósito de la investigación, los pasos del proceso se configuran en ocho capítulos, como lo muestra la figura 1.1.

Figura 1.7: Esquema de relación de capítulos de la tesis



El capítulo 2, de la investigación analiza la forma de eficiencia débil del mercado chileno, asimismo de la consistencia en los resultados obtenidos con la teoría de finanzas corporativas. En este análisis se utilizará un periodo sin pandemia que comprende entre 2007 a 2017, para verificar el mercado antes de la emergencia sanitaria.

El capítulo 3, considera la irrupción del COVID-19 en Chile, utilizando el periodo entre el 1 de enero de 2019 al 11 de septiembre de 2020. En el transcurso de la investigación el período de alta incertidumbre ofrece la oportunidad de revisar cómo actuó el mercado chileno frente a las noticias de la pandemia, por sector industrial, para analizar qué industria responde con mayor eficiencia ante la emergencia sanitaria. Esta revisión de eficiencia de mercado se realiza por medio de un estudio de eventos, en el cual serán importantes las noticias de la pandemia

a nivel mundial como local, fijando el evento inicial con el primer caso de COVID-19 en Chile (3 de marzo de 2019).

El capítulo 4, somete a prueba al modelo CAPM y sus principales modificaciones (Fama French de tres factores, Fama Cahart de cuatro factores y Fama French de cinco factores), para determinar cuál es el modelo de mejor desempeño en el mercado chileno. Estos tres modelos han surgido a partir de investigadores que han sometido a los modelos a pruebas empíricas en mercados desarrollados, donde el principal investigador es Eugene Fama, el que fue merecedor del premio Nobel en 2013, por la contribución de investigaciones acerca de los precios de los activos. Este capítulo comprende un tiempo de alta incertidumbre como lo es la pandemia del COVID-19, que produjo a nivel mundial caídas históricas de las acciones. El capítulo se plantea responder lo siguiente: ¿qué modelo captura mejor rendimiento en la predicción de los retornos de los activos que componen el índice IPSA de la bolsa de valores de Santiago de Chile?, tanto en periodo sin pandemia y con crisis sanitaria.

El capítulo 5, considera el período de crisis provocado por la irrupción de la pandemia, para la verificación de variables que incorporen el sentimiento del inversor, buscando factores de riesgo que permitan superar el supuesto de comportamiento racional de los inversionistas (aversión al riesgo), que se ha considerado por los modelos originales de valoración de activos como una constante.

En el capítulo 6, una vez que se obtenga el modelo de mejor rendimiento (capítulo 3) se va a extender este modelo con factores de riesgo que capturan el sentimiento de los inversionistas y que han sido evaluados estadísticamente en el capítulo 5. Los factores de riesgo que se evaluarán provienen de comentarios de la red social Twitter, índices del miedo de los mercados como se conoce a los índices VIX, y dos índices construidos en esta investigación con datos propios de la pandemia, utilizando el número de casos confirmados de COVID-19, en Chile, Perú, Colombia y México y de muertes ocasionadas por el virus, a nivel mundial.

El capítulo 7, presentará un estudio más disruptivo que los anteriores, pero en la misma línea de la investigación, que aborda la pertinencia de llevar los modelos de valoración de la mano con los avances tecnológicos de las últimas décadas, sobre todo lo que tiene relación con el Big Data y Machine Learning. En este caso se utilizarán datos desde la plataforma que provee Google, acerca de la intensidad y volúmenes de búsqueda en Internet, donde se analiza una base de

datos de términos, adaptada a los mercados latinos para analizar si la variación de la intensidad de consultas en un periodo de cinco años, con frecuencia semanal, puede ser utilizada como predictor para los índices bursátiles que conforman el Mercado Integrado Latino Americano (MILA).

Capítulo 2 : Eficiencia de mercado en su forma débil y aplicación de prueba de estacionariedad al modelo de valoración CAPM en el mercado bursátil chileno.

2.1.-Resumen del Capítulo

Los modelos de valoración de activos más reconocidos por la teoría y la práctica como el CAPM (Capital Asset Pricing Model) y el APT (Arbitrage Pricing Theory) presuponen que los mercados financieros son eficientes. Esta suposición ha evolucionado con el paso del tiempo encontrándose una amplia diversidad en la eficiencia de los mercados asociada al concepto de igualdad de condiciones de información, pero también dependiendo del nivel de desarrollo o tipo de región donde se realiza el estudio. A partir de la teoría de mercados eficientes de Fama y French, es necesario para este trabajo de investigación establecer el estado de la forma de eficiencia financiero del mercado chileno antes de la pandemia del COVID-19, además es importante establecer la validez del modelo CAPM de un factor con respecto a su aplicación en el mercado chileno.

Este capítulo analiza series de tiempo en el mercado financiero chileno, entre los años 2007 y 2017 con el fin de probar la hipótesis de eficiencia de mercado (Fama, Eugene, 1970). A partir del modelo de valoración CAPM (Capital Asset Pricing Model), en periodo sin crisis sanitaria. El objetivo es la revisión del mercado en condiciones normales. Se aplica la prueba de Dickey Fuller Aumentada a las correspondientes regresiones para determinar si los precios en primera diferencia (retornos) de las acciones son estacionarios o poseen características de camino aleatorio, con este procedimiento de contesta la pregunta de ¿El mercado chileno se encuentra en la forma de eficiencia débil?.

Para analizar la validez de la aplicación del modelo CAPM de un factor, se utilizarán tres pruebas: test de dos etapas de regresiones, test Black, Jensen and Scholes (BJS) y test Black, Jensen and Scholes – Fama Macbeth. Respondiendo a las siguientes interrogantes: ¿Es coherente la relación riesgo retorno?, ¿Los datos se distribuyen linealmente?, y por último ¿la fuente de riesgo sistemático es la apropiado para el mercado, en el período examinado?.

Como resultado se obtiene que, en el mercado de valores de Chile, los retornos son estacionarios. La importancia de que las series sean estacionarias radica en la en que los retornos se comportan de acuerdo a la información pasada con una determinada media y varianza,

Revisando la validez del modelo CAPM de un factor se obtiene que: el intercepto no es igual a cero, el cual en este caso no corresponde al bono anual del banco central en UF (unidad de fomento), en el proceso de revisión es el que mejor se ajusta para la revisión de las series mensuales de los retornos en los años

estudiados, además no se cumple la relación positiva entre riesgo retorno, que es la exigencia de mayor retorno en presencia de mayor riesgo. Con respecto al riesgo que captura el modelo, presenta baja explicación a los rendimientos del mercado, esto indica que faltan factores de riesgo que afectan a este mercado en el modelo aplicado.

2.2.-Introducción

La génesis de la valoración de activos está dada por la teoría de [\(Markowitz, 1952\)](#), la cual se basa en los diagramas de media y desviación estándar, que representan el riesgo y la rentabilidad de un activo cualquiera. La existencia de una cartera de activos genera una combinación de riesgo y retorno de los activos donde existe una única frontera eficiente.

Los supuestos que establece la teoría de valoración de Markowitz son los siguientes: todas las decisiones están basadas en la media y desviación estándar de los rendimientos. Los participantes del mercado son aversos al riesgo y prefieren los mayores rendimientos posibles en un mercado determinado. Los mercados son perfectos y por lo menos tres activos de una cartera no han de tener una correlación perfecta.

El modelo establece que, de un total combinado de activos, el conjunto de mínima varianza forma una frontera eficiente ubicada en la parte superior de la curva de la cartera. Esta parte de la curva está formada por las carteras eficientes donde se obtiene la mejor combinación de media varianza. Este modelo es la base de los modelos de valoración vigentes, pero no es aplicable en la teoría de finanzas actuales, debido a sus restricciones y supuestos muy minimizadores de la realidad. Además de considerar que todas las decisiones realizadas se basan en la media y varianza.

Al incluir un activo libre de riesgo en el modelo, considerado en los análisis como los bonos emitidos por los gobiernos, conecta el modelo más a la realidad, ya que este activo posee la particularidad que se conoce a priori su rentabilidad y en teoría no tiene riesgos, y al combinarlo con los activos riesgosos se obtiene una frontera eficiente.

Esta teoría de carteras de media y varianza va a ser la base para dar paso al modelo de valoración de activos más conocido que es el CAPM (Capital Asset Pricing Model).

El riesgo en la valoración de empresas se divide en dos, el riesgo diversificable y no diversificable. Este último riesgo representa el mercado y no se puede evitar, por lo que hace interesante poder precisar si en la valoración de activos este riesgo es el adecuado. Dicho aspecto de la disciplina nace con el aporte de [\(Markowitz, 1952\)](#) y de [\(Sharpe W. , 1964\)](#).

En Chile reviste un hecho especial el analizar la eficiencia de la bolsa de valores y uno de sus métodos de valoración, debido a que el 8,6% de los fondos de pensiones de los chilenos, se encuentra invertido en el índice IPSA (Índice de Precios Selectivo de Acciones), lo que asciende a US\$ 18.542,37 millones (Infante, 2018). Con considerables aumentos en inversión en el último tiempo. Las administradoras de los fondos de pensiones (AFP) compraron papeles por \$171.712 millones (US\$ 273,3 millones) y registraron su mayor adquisición en papeles locales en casi dos años. Esto, en medio del descenso de -4,48% del IPSA durante mayo de 2018. (Inversiones, 2018)

2.3.-Hipótesis de Eficiencia de Mercado (Efficient Market Hypothesis o EMH)

La eficiencia de mercado está basada en la información que se tenga acerca de las acciones que se transan y cómo los precios de estos activos recogen datos de los mercados y la reflejan en sus precios futuros. Los precios se comportarán de acuerdo con la información que se tenga en un mercado en particular, por lo tanto, para mantener un juego justo (Fair game), tanto oferentes como demandantes de acciones deben contar con los mismos datos. Los precios, desde el punto de vista de la información, deben ser impredecibles. De acuerdo con esto, los retornos de los activos deben ser un juego justo (Samuelson, 1965).

Por lo tanto, este precepto es que los analistas de inversiones que estén en la búsqueda de información que puede afectar en los precios y puedan generar ganancias de acuerdo con la obtención de nuevos datos relevantes, no pueden influir en ganancias anormales, ya que, los datos públicos del mercado están disponibles para todos. Esto es sustancial toda vez que se analiza un mercado emergente, debido a que existe una gran cantidad de análisis y datos disponibles en mercados financieros desarrollados como Norteamérica y Europa, hace que los mercados tengan una forma de eficiencia fuerte por la información disponible, en cambio en los países con mercados financieros de poco desarrollo, el acceso a la información es más escasa y esto deduce que es más común encontrar mercados en forma débil o semi-fuerte.

Esta teoría de mercado, desarrollada por (Fama, Eugene, 1970), eficiente en finanzas de acuerdo con la información de los activos, ha permanecido vigente por cuarenta y ocho años.

Un mercado en el que los precios reflejan la totalidad de la información existente es denominado eficiente, de acuerdo con tres formas de eficiencia:

- 1) **Eficiencia forma débil:** En donde los precios de los activos reflejan toda la información histórica.

Bajo este tipo de eficiencia, los precios actuales reflejan el comportamiento pasado de los precios de los activos y estos no necesariamente serán el reflejo de los precios futuros. En este sentido cobra más sentido la dependencia de los precios día a día.

Esta forma de mercado implica que utilizando el análisis técnico los inversores no podrían predecir el comportamiento futuro de los precios y, por ende, no se podrán obtener rentabilidades extraordinarias de acuerdo con el riesgo que enfrentan los activos.

- 2) **Eficiencia forma semi-fuerte:** El activo refleja toda la información, historia y la información pública disponible.

En esta forma, los precios reflejan toda la información pública. No solo se tiene la información de precios y volúmenes históricos, también cualquier información contable de las empresas, información sobre el estado de la economía de un mercado en particular; como fusiones y adquisiciones. Toda esta información pública es relevante para la valoración de los activos financieros, por lo tanto, ningún tipo de análisis del tipo fundamental podría obtener rentabilidades anormales.

- 3) **Eficiencia forma fuerte:** El activo refleja toda la información pública y privada disponible.

La eficiencia de mercado indica que los precios de los activos reflejan toda la información disponible tanto pública y privada, por lo tanto, la nueva información que afecta a los precios se incorpora rápidamente. Este supuesto implica que obtener predicciones de precios futuros basándose en información pasada, llevando a cabo estrategias activas de inversión en base a estas predicciones, no sería útil.

2.4.-Modelo CAPM (Capital Asset Pricing Model)

El modelo CAPM ha recorrido un largo camino desde su creación. Al principio fue declarado por los investigadores como un modelo de predicción de precios en los mercados de valores, pero como se fueron evidenciando fallas en el modelo, no se insistió en el propósito inicial (Chaudhary, 2016). Sin embargo, es

uno de los modelos más populares para realizar estudios de precios de los activos hasta ahora, siendo usado por las corredoras de valores en sus análisis de activos financieros y portafolios recomendados.

El modelo de valoración de activos CAPM (Capital Asset Pricing Model), es uno de los métodos de valoración financieros más importantes. En él se evalúa la relación riesgo-retorno de un activo individual o de una cartera de activos, del cual se han realizado múltiples estudios e investigaciones.

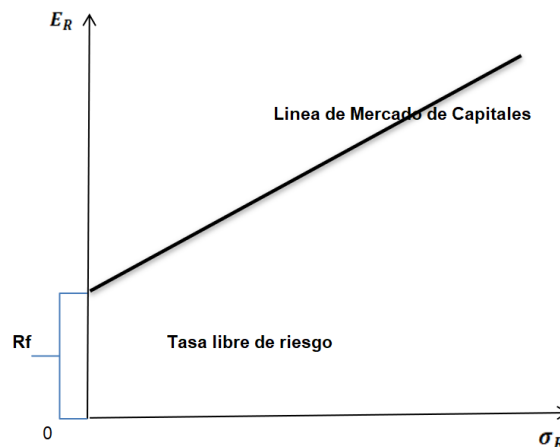
La concepción inicial se centró en la búsqueda de un modelo que reflejara el equilibrio de los mercados de capitales a través de su función de utilidad:

$$U = f(E_w, \sigma_w) \quad 2.1$$

Donde E_w , Representa la expectativa de riqueza futura y σ_w el predictor determinado por desviación estándar, de la posible divergencia de la actual riqueza y futura riqueza desde E_w .

Se supone que, bajo la racionalidad económica de los inversionistas, estos prefieren una mayor riqueza esperada futura a una riqueza esperada menor, ($dU/dE_w > 0$) (2). Pero esta racionalidad cambia cuando los agentes deben asumir mayores riesgos, debido a que los inversores son adversos al riesgo, por lo tanto, eligen inversiones que tengan menor riesgo σ_w , a un mayor nivel de la esperanza de riqueza ($dU/d\sigma_w < 0$), esto hace que la curva de indiferencia entre la relación de la esperanza de riqueza y el riesgo tenga pendiente positiva (Figura 2.1):

Figura 2.1: Relación Riesgo Tasa de Expectativa de Retornos.



Se asume que un inversor decide comprometer una cantidad dada de riqueza (W_1), esta será su riqueza inicial, y W_t es la riqueza al término del periodo t y R el retorno de la inversión, entonces la relación es:

$$R = \frac{W_t - W_1}{W_1} \quad 2.2$$

Donde tenemos que la riqueza al término del periodo t es la siguiente ecuación:


$$W_t = RW_1 + W_1 \quad 2.3$$

Esta relación permite expresar la utilidad del inversionista en función de R (tasa de retorno), debido a que la riqueza final del inversionista está relacionada directamente con la tasa de retorno.

$$U = g(E_R, \sigma_R) \quad 2.4$$

El modelo considera que el inversor elige un set de inversiones en la curva que maximicen su utilidad

Figura 2.2: Curvas de indiferencia entre riesgo y retorno esperado.



Los puntos de las curvas (I, II y III) indican la mayor utilidad, de acuerdo con el riesgo y el retorno exigido por el inversionista. Cualquier otro punto bajo la curva de indiferencia representa ineficiencia en el mercado de valores en particular.

Si consideramos dos planes de inversiones que tiene el inversionista A y B (Ver Figura 2.3), estos incluyen uno o más activos. El razonamiento es el siguiente: Si el inversionista coloca su riqueza en el plan de inversión A, el resto queda $(1-\alpha)$ en el plan de inversión B, entonces el retorno esperado será un punto que se encuentra en la curva del plan de inversión A y el plan de inversión B, descrito en la siguiente ecuación (Sharpe W., 1964):


$$E_{Rc} = \alpha E_{Ra} + (1 - \alpha) E_{Rb} \quad 2.5$$

Y el predictor del riesgo (la desviación estándar) está dado por:

$$\sigma_{Rc} = \sqrt{\alpha^2 \sigma_{Ra}^2 + (1 - \alpha)^2 \sigma_{Rb}^2 + 2r_{ab}\alpha(1 - \alpha)\sigma_{Ra} \sigma_{Rb}} \quad 2.6$$

Cabe señalar que donde se sitúe el retorno de la inversión, no sólo va a depender del retorno esperado de acuerdo con el riesgo, sino que también de la correlación de las otras oportunidades de inversión sobre la curva. Por esta razón es importante revisar el equilibrio de mercado. (Sharpe W. , 1964).


Figura 2.3: Planes de inversión



Para determinar el equilibrio en el mercado de capitales, se debe suponer una tasa libre de riesgo común para todos los inversionistas, además con capacidad de prestar o pedir prestados fondos en igualdad de condiciones. Por otro lado, se asume la homogeneidad de las expectativas de los inversionistas.


El modelo obtiene su equilibrio en la relación lineal simple entre la desviación estándar y el retorno esperado. Si los retornos se ubican sobre la línea de mercados de capitales, marcan ineficiencia del mercado debido a la ausencia de diversificación de los activos. En estos puntos, la relación entre retorno esperado y riesgo es inconsistente; sin embargo, existe una relación consistente entre retorno esperado y riesgo total, que es lo que se denomina riesgo sistemático (Sharpe W. , 1964).

Figura 2.4: Equilibrio de Mercado de Capitales.



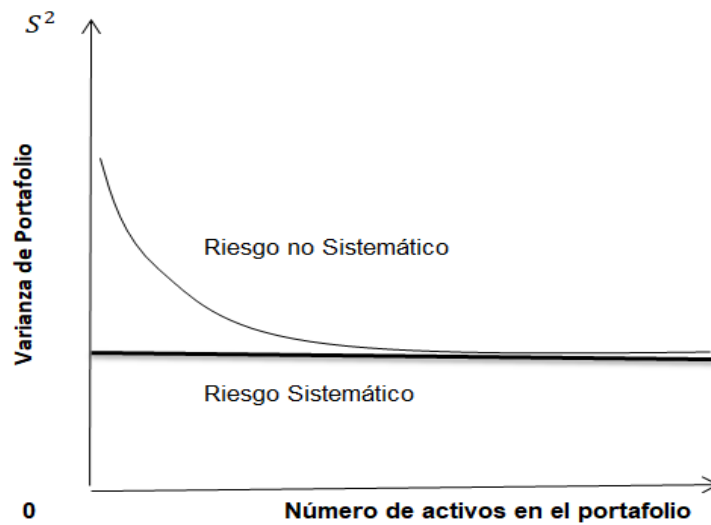
La figura 2.4, muestra la relación entre activos de capital (i) y una eficiente combinación de activos (g). La curva (igg') señala todas las combinaciones entre retorno esperado y riesgo, y la curva de entre ZP representa la línea de mercado de capitales, que es tangente a g, este punto representa la combinación eficiente de los activos (Sharpe W. , 1964).

Figura 2.5: Recta de regresión mercados de capitales.



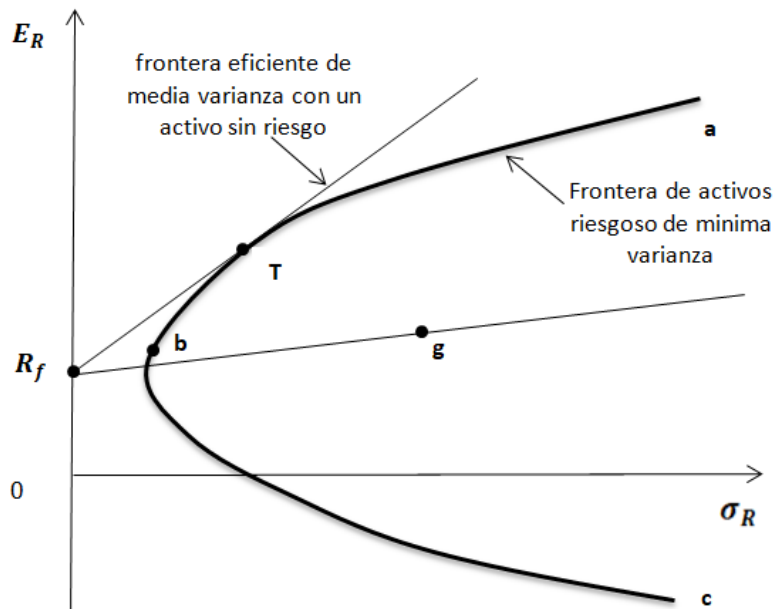
La variación en la curva R_i , corresponde al riesgo total de los activos. Uno de estos riesgos se denomina riesgo sistemático. El resto que está sin correlacionar con R_g , corresponde al riesgo no sistemático. La formulación entre R_i y R_g puede ser utilizado como modelo predictivo ex - ante. En la práctica, mide cómo el valor predictivo de R_i cambia, con los cambios que se producen en R_g .

Figura 2.6: Riesgo total de portafolio.



El inversionista puede diversificar para bajar el riesgo de sus activos, pero no puede hacer nada frente al riesgo que se produce en la actividad económica (riesgo sistemático) (Sharpe W., 1964).

Figura 2.7: Oportunidades de inversión



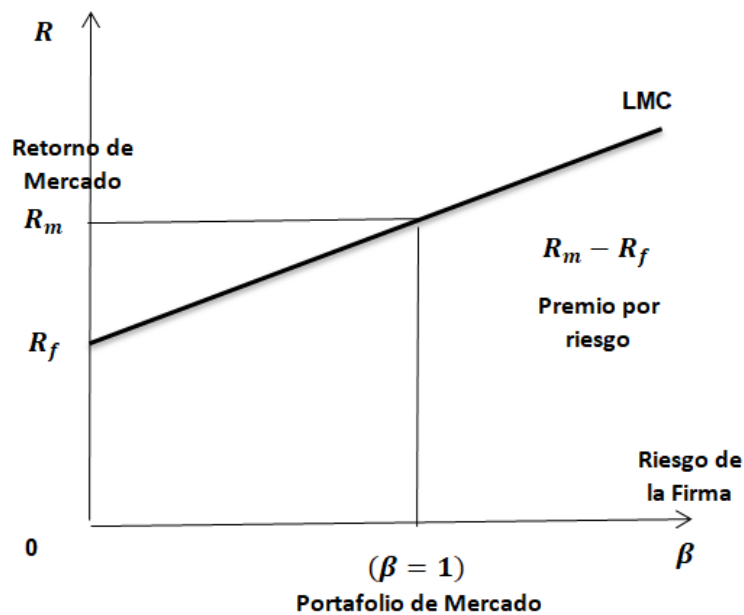
Los inversores tienen la misma función de distribución, por lo tanto, hace que exista una distribución de probabilidad conjunta. Además, se supone que todos los inversores asignan la misma media, varianza y covarianza a la distribución de estos rendimientos (Lintner, 1965)

Otros supuestos importantes que se establecen es que cada inversor puede invertir todo lo que requiera en activo libre de riesgo, como también sus ganancias; contrario a lo que se establecía anteriormente: que no estaba permitido pedir prestado.

Con este supuesto de endeudamiento surge una conclusión importante para el trabajo de Sharpe y Lintner, que es que, al seguir este supuesto de endeudamiento a una tasa libre de riesgo, cada inversor individual tomará decisiones idénticas cuando forme sus carteras de inversión. Como consecuencia de este aporte, solo un punto en la frontera de eficiencia de media varianza será el importante. El punto T de la figura 2.7, es el mismo para todos los inversionistas. (Sharpe W. , 1964)

La cartera es la de mercado y la única diferencia en el retorno de los inversionistas es la elección de su perfil de riesgo.

Figura 2.8: Modelo CAPM.



El modelo que establece la relación del retorno de los activos individuales y el riesgo sistemático se representa con la siguiente ecuación:

$$E(R_i) = R_f + \beta_i E(R_m - R_f) \tag{2.7}$$

Donde:

$E(R_i)$: Esperanza del retorno esperado por el activo i-ésimo.

R_f : Retorno que obtiene el activo libre de riesgo.

$E(R_m)$: Esperanza del retorno de la cartera de mercado.

β_i : Riesgo sistemático del activo i-ésimo.

Según este modelo, los inversionistas sólo son compensados con el riesgo sistemático. La medida en que se compensa a los inversores depende de dos factores, el beta del mercado y la prima de riesgo del mercado. Debido a que el riesgo no sistemático puede ser eliminado por la diversificación, los inversionistas no son compensados por ello. El beta del mercado también se puede denotar como la covarianza de su retorno con el mercado, dividida por la varianza del rendimiento del mercado.

$$\beta_i = \frac{\text{Covarianza}(R_i, R_m)}{\text{Varianza}(R_m)} \quad 2.8$$

Donde:

R_i : Retorno del activo i-ésimo, R_m : Retorno de mercado.

Cuando un valor tiene una beta igual a cero, el retorno esperado es igual a la tasa libre de riesgo. Cuando un valor tiene una beta de uno, el rendimiento esperado del activo i es igual al rendimiento esperado del mercado.

Supuestos del modelo.

1. Los inversionistas son aversos al riesgo y maximizan la utilidad esperada de su riqueza al fin del período.
2. Los inversionistas son tomadores de precios y tienen expectativas homogéneas respecto de los retornos de los activos y su distribución de probabilidad.
3. Existe un activo libre de riesgo tal que los inversionistas pueden prestar o pedir prestado cantidades infinitas a la tasa libre de riesgo.
4. Las cantidades de los activos son fijas. Todos los activos son transables y perfectamente divisibles.
5. Mercados sin fricciones, información sin costo y simultáneamente disponible para todos los inversionistas.
6. No existen imperfecciones de mercado tales como impuestos, regulaciones o restricciones a la venta corta.

Desde 1964 el modelo ha recibido una gran aceptación en la disciplina de las finanzas, sin embargo, se evidenciaron muchos problemas desde el principio de su aplicación (Fama, Eugene; Crum, Roy, 1977).

Este modelo está basado en supuestos irreales debido a que es un modelo estático, establecido en la proyección de rendimientos pasados que no necesariamente se replicarán en el futuro. Además, la oferta de activos financieros con riesgo está determinada exógenamente como lo son el tipo de interés o la tasa que remunera el capital. No existen costos de transacción ni impuestos. A todos los inversores les interesa la media varianza (Markowitz, 1952). La información que poseen los distintos agentes es la misma, no existe asimetría de información.

Otro aspecto en discusión acerca del modelo es la adecuada tasa libre de riesgo. El premio por riesgo no puede ser medido con precisión, ya que dependerá de la estimación del retorno del activo y de la tasa libre de riesgo escogida. El riesgo sistemático no sólo es inestable, también no se sabe cómo calcular el beta de un activo financiero a futuro, por tanto, es el resultado de los retornos pasados del activo y el mercado.

El coeficiente beta mide la relación entre el retorno de un activo y el retorno del mercado. Es utilizado para la medición del riesgo que no es específico de algún sector económico y que afecta a todas las empresas.

Si el coeficiente beta es:

-Mayor a uno el riesgo no diversificable de la inversión es superior al del promedio del mercado,

-Menor que uno: el riesgo no diversificable de la inversión es inferior al del promedio del mercado.

-Igual a uno: la variación del riesgo no diversificable de la inversión tiende a seguir al mercado.

El principal problema del modelo CAPM es que proyecta los retornos futuros con información fiable de los retornos pasados, no obstante, deja de lado los factores exógenos propios del mercado, como lo son las condiciones para mercados alcistas o bajistas de acuerdo con el comportamiento social, político y económico en el cual se encuentran insertas las empresas.

Este modelo ha sido desarrollado en mercados económico-financieros desarrollados. En ellos, las variables macroeconómicas y financieras son recopiladas, almacenadas e interpretadas por instituciones por más de cien años, es por eso la importancia de investigar si estos modelos pueden predecir con

mayor exactitud los precios de los activos en mercados subdesarrollados y/o emergentes.

2.5.-Metodología

2.5.1.-Paseo aleatorio (Random Walk)

Se define caminata aleatoria, cuando los hechos del futuro no se pueden predecir en base al comportamiento del pasado, ya que su media y varianza no son estables en el tiempo. Cuando este concepto se aplica al mercado de valores, significa que es a corto plazo y no se pueden pronosticar. Por lo tanto, las asesorías financieras, predicciones de ganancias, análisis de patrones gráficos, son inútiles (Malkiel, 1973).

En sus inicios, la descripción del movimiento aleatorio buscó explicar los movimientos de la naturaleza, del comportamiento humano. De ahí se llevaron estos descubrimientos a los precios tanto bursátiles como económicos.

Uno de los primeros investigadores en relacionar este concepto a los activos financieros fue Fama (Fama, Eugene, 1965); no obstante, fue Malkiel (Malkiel, 1973) quien popularizó este concepto en su obra: “A Random Walk Down Wall Street: The Time-tested Strategy for Successful Investing”, donde comparó la asertividad de un mono con los ojos vendados lanzando dardos a las páginas financieras de un periódico, con la habilidad de los expertos en inversión para seleccionar una cartera asegurando que no habría diferencia alguna entre las rentabilidades de las dos carteras.

El recorrido aleatorio (RA) o Random Walk (RW) determina que la formación de los precios de los instrumentos se genera de forma impredecible y que, por tal motivo, no es posible pronosticar sistemáticamente el precio futuro de los activos, imposibilitando la ganancia segura por parte de alguno de los participantes del mercado. Parte del supuesto que el mercado cuenta con muchos participantes que constantemente están valorando (por análisis técnico o análisis fundamental). (Duarte, 2014).

Se dice que un proceso estocástico es estacionario si su media y su varianza son constantes en el tiempo y si el valor de la covarianza entre dos periodos depende sólo de la distancia o rezago entre ambos, y no del tiempo en el cual se calculó la covarianza. Es una serie estable a lo largo del tiempo, cuando no se aprecian aumentos y disminuciones sistemáticos de sus valores. ¿Por qué las series de tiempo estacionarias con tan importantes en los estudios?, porque si una serie

resulta ser no estacionaria, sólo se puede estudiar el comportamiento durante el periodo del estudio en cuestión. Por lo que, cada conjunto de datos de la serie de tiempo corresponde a un episodio en particular, por lo tanto, no sería posible generalizar los hallazgos obtenidos para otros períodos. Las consecuencias de estar en presencia de una serie de tiempo que tenga raíz unitaria o no estacionaria nos llevan a conclusiones erróneas, debido a que las regresiones son espurias (Gujarati & Porter, 2009), esto puede mostrar estadísticas robustas como R^2 (Coeficiente de determinación) altos, el que indicaría la relación de las variables. Pero al existir caminata aleatoria esto sería falso y llevaría a conclusiones erróneas.

Uno de los procesos estocásticos no estacionarios es el denominado de caminata aleatoria (MCA). Existen dos tipos de caminatas aleatorias, una es sin intercepto y otro es con intercepto.

2.5.2.-Pruebas de estacionariedad

Las pruebas de estacionariedad se pueden realizar mediante análisis gráfico o mediante la aplicación de pruebas estadísticas, representar las series de precios en gráficos son útiles para visualizar intuitivamente la existencia de estacionariedad, los gráficos dan una pista inicial cuando se visualizan las tendencias, que indica inicialmente que está variando la media y los precios tienen un comportamiento de caminata aleatoria.

Otro método es por medio de revisión de autocorrelación ¿Cómo se puede saber por medio de este método si una serie es estacionaria o no? Cuando se obtiene el correlograma, se debe ver la variación que muestra la autocorrelación, si esta es baja y se mantiene en la media indica que es una serie estacionaria, si muestra mucha variación estaría indicando que estamos en presencia de una serie de tiempo no estacionaria.

Luego, existen otras técnicas suscritas al análisis más fundamental que serán indicadas a continuación.

2.5.3.-Test de Dickey-Fuller (DF)

Para determinar si un proceso es o no estacionario podemos utilizar la prueba de raíces unitarias Dickey - Fuller (DF) o Dickey-Fuller aumentado (ADF). (Dickey & Fuller, 1979). Ellos desarrollaron estas pruebas en modelos para realizar el análisis de la estacionariedad a los procesos estocásticos.

El planteamiento del modelo es el siguiente:

$$z_t = a_1 z_{t-1} + v_t \quad 2.9$$

Si a_1 es menor a 1 la variable z_t está correlacionada, pero será estacionaria mientras que si es igual a 1 o mayor será no estacionaria y su variancia crecerá de forma explosiva.

La hipótesis por contrastar es:

$$H_0: a_1 = 1 \text{ Versus } H_1: a_1 < 1$$

En un proceso auto regresivo AR(1) y para realizarlo se utiliza la relación de la formula (10) donde $\nabla = z_t - z_{t-1}$ y $d_1 = a_1 - 1$, el parámetro d_1 tomará valores en el intervalo comprometido entre dos y cero, $-2 < d_1 < 0$, si el valor absoluto del parámetro a_1 , es menor que la unidad $-1 < a_1 < 1$.

El test DF consiste en contrastar:

$$H_0 : d_1 = 0 \text{ Tiene Raíz unitaria y no estacionariedad.}$$

$$H_1 : d_1 < 0 \text{ No tiene Raíz unitaria y estacionaria.}$$

2.5.4.-Test de Dickey-Fuller Aumentado (ADF)

El test ADF también consiste en el mismo objetivo del test DF: Contrastar la hipótesis de nulidad de d_1 , pero en una relación aumentada con la inclusión de valores retardados de ∇z_t , si se considera necesario pueden incluirse también el término constante (drift) y la tendencia, igual que el test DF, de forma que el contraste, en caso de un aumento de dos retardos, se realiza en la relación:

$$\nabla z_t = d_1 z_{t-1} + d_0 + d_2 t + d_3 \nabla z_t(-1) + d_3 \nabla z_t(-2) + \dots \quad 2.10$$

Los valores críticos más utilizados son los propuestos por MacKinnon. Para este estudio se realizará por medio del software econométrico E-Views, con las salidas de las regresiones efectuadas. La hipótesis nula, o hipótesis a contrastar, es la de integración o no estacionariedad de la perturbación aleatoria frente a la alternativa de no integración o estacionariedad. (Jordan, 2012)

La razón de realizar la prueba de estacionariedad de la serie de tiempo de los retornos de las acciones es: en primer lugar, revisar la eficiencia débil de Fama & French, que dice relación en donde los precios contienen la información histórica,

y la segunda razón es para aplicar las pruebas al modelo CAPM, ya que los retornos deben ser aleatorios o si no invalidan el contraste.

2.5.5.-Test en dos etapas

El primer test que se aplicará consiste en realizar dos etapas de regresiones. La primera es someter a las cuarenta acciones correspondientes al índice IPSA chileno a regresiones individuales entre el periodo 2007 y 2017, con datos de precios mensuales, para la obtención de sus betas (estimados del riesgo sistemático) y para obtener el "Security Market Line (SML)".

$$E(R_{it}) = E(R_{fi}) + \beta_i E(R_{Mt} - R_{fi}) + \varepsilon_{it} \quad 2.11$$

Donde:

$E(R_{it})$: Corresponde a la esperanza del exceso de retorno del activo sobre la tasa libre de riesgo en el periodo t., $E(R_{fi})$: Intercepto de la regresión (Activo libre de riesgo), β_i : Corresponde al beta estimado del activo i, $E(R_{Mt} - R_{fi})$: Exceso de retorno del mercado sobre la tasa libre de riesgo en el periodo t., ε_{it} : Perturbación aleatoria en el periodo t.

La ecuación (2.11) es en términos de retornos esperados. Pero sus implicaciones deben ser probadas con datos sobre los activos de periodo por periodo y los rendimientos de cartera. Se necesita elegir un modelo de rendimientos período por período que permita utilizar rendimientos promedio observados para probar las condiciones de rendimiento esperado. Pero uno que, sin embargo, es lo más general posible. Se sugiere la utilización de la siguiente generalización estocástica de la ecuación (2.11). (Fama, Eugene; MacBeth, James, 1973)

$$\check{R}_{it} = \check{\gamma}_{0t} + \check{\gamma}_{1t}\beta_i + \check{\gamma}_{2t}\beta_i^2 + \check{\gamma}_{3t}S_i + \check{\eta}_{it} \quad 2.12$$

Condiciones derivadas de los supuestos del modelo:

C1: El intercepto es igual al activo libre de riesgo utilizado en el modelo testeado. (Lintner, 1965).

C2: Los inversionistas son aversos al riesgo, por lo tanto, a mayor riesgo se exigirá mayor retorno, esto es: $E(R_{Mt} - R_{fi}) > 0$.

C3: La relación entre retorno esperado y el riesgo es lineal.

C4: Sólo β_i , (riesgo sistemático) afecta a los rendimientos del activo i, no existe otro riesgo del sistema que está inserto el activo que afecte el precio de los activos.

De acuerdo con lo anterior se establecen las siguientes hipótesis para probar el modelo:

H₁: Si $\hat{\gamma}_0 = R_f$, (Condición C1).

H₂: Si $\hat{\gamma}_1 > 0$, (Condición C2).

H₃: Si $\hat{\gamma}_2 = 0$, (Condición C3).

H₄: Si $\hat{\gamma}_3 = 0$, (Condición C4).

Con la ecuación anterior se someterá a una regresión a las 40 acciones, correspondiente al índice IPSA de Chile. Según con el modelo CAPM el intercepto de la regresión ($\check{\gamma}_{0t}$ de la ecuación (2.12)) debe ser cero, para la comprobación de este supuesto se utilizará la siguiente ecuación:

$$R_{it} = \gamma_0 + \gamma_1\beta_i + \eta_{it} \quad 2.13$$

Donde:

R_{it} : Corresponde al exceso de retorno del activo sobre la tasa libre de riesgo en el periodo t, γ_0 : Intercepto de la regresión, γ_1 : Coeficiente de la regresión, β_i : Beta estimado del activo i-ésimo, η_{it} : Término del error aleatorio de la estimación.

Esta regresión debe ser ejecutada para todos los activos en estudio, donde el resultado debiese corresponder a:

γ_0 : 0 y γ_1 : debe ser el promedio de los retornos de mercado por sobre la tasa libre de riesgo

Para realizar el test de no linealidad, ya que como se dijo anteriormente el CAPM se basa en el supuesto que los rendimientos de los activos están relacionados linealmente con el riesgo sistemático (β), para probar la veracidad de esta hipótesis (H₁) se agrega un término adicional a la ecuación anterior (2.13).

$$R_{it} = \gamma_0 + \gamma_1\beta_i + \gamma_2\beta_i^2 + \eta_{it} \quad 2.14$$

Donde:

γ_2 : Coeficiente de la regresión, β_i^2 : Corresponde al beta estimado al cuadrado del activo i-ésimo.

Esto debe indicar si el modelo posee una relación lineal entre el retorno y el riesgo sistemático (β), esto se cumple para el CAPM, cuando: $\gamma_2 = 0$.

Por último, se prueba el riesgo sistemático (test del riesgo no sistemático). El CAPM indica en uno sus supuestos que el único riesgo que a los inversionistas les importa es este. Los demás factores que puedan influenciar este riesgo no importan, para realizar este test, se adicionará otro término a la ecuación anterior (2.14)

$$R_{it} = \gamma_0 + \gamma_1\beta_i + \gamma_2\beta_i^2 + \gamma_3S(\eta)_i + \eta_{it} \quad 2.15$$

Donde:

γ_3 : Es el coeficiente de la regresión, $S(\eta)_i$: Corresponde a la varianza de los errores del activo i-ésimo, obtenido en la primera regresión.

Para que se cumpla esta hipótesis γ_3 debe ser igual a cero.

2.5.6.-Test Black, Jensen, and Scholes (BJS)

Este test fue introducido en 1972, debido a desde que se originó el modelo de valoración es necesario verificar su validez en la determinación del valor de los activos.

El primer paso del procedimiento de prueba del modelo establece que se deben formar portafolios de acciones, en donde se deben juntar de acuerdo con su nivel del coeficiente beta. Las acciones se conforman en grupo de diez portafolios en que está considerado el 10% del total del mercado, con el criterio de mayor nivel beta a menor nivel. La razón de este ranking es que a mayor riesgo mayor retorno; por lo tanto, se trata de obtener la mínima varianza dentro de los portafolios y es evitar la no dependencia de los errores.

La agrupación de los grupos de acciones en conformación de portafolios busca ganar eficiencia; sin embargo, esta agrupación basada en el estimador beta (β), puede no obtener estimaciones imparciales de la cartera "Beta". Este procedimiento introduciría un sesgo para la prueba que utiliza esta selección. Para evitar este sesgo el procedimiento incorpora que, para calcular el estimador beta del siguiente periodo, se utilizan los retornos de los activos del periodo anterior. De acuerdo con el resultado del estimador en el próximo periodo, se reagrupan las carteras para el próximo periodo de acuerdo con el ranking antes descrito.

Este proceso también debe considerar el supuesto de estacionariedad del estimador beta a través del tiempo. Este solo será válido si el coeficiente no posee caminata aleatoria.

Se debe asumir que los coeficientes betas son estacionarios a través del tiempo, ya que este proceso de orden de cartera resulta más complicado cuando algún activo posee betas que no son estacionarios a través del tiempo (Black, Jensen, & Scholes, 1972)

El test BJS estudia el rendimiento del CAPM en las carteras en lugar de las acciones individuales. Al crear carteras, una cierta cantidad de “el riesgo específico de la empresa” se diversificará de acuerdo con la teoría de cartera moderna.

Este test debe seguir los siguientes pasos:

Paso 1: Durante el período de investigación, se estiman los rendimientos en exceso de cada valor de una serie temporal de los retornos de acciones del IPSA ($R_{it} - R_{ft}$) y el rendimiento en exceso del índice de precios selectivo de acciones IPSA (Premio por riesgo de mercado), que se define como el poder para la cartera del mercado ($R_{mt} - R_{ft}$).

Paso 2: Durante el mismo período, se estiman las betas de las acciones al procesar las regresiones de los excesos de retornos de las acciones del IPSA con el exceso de retornos del mismo periodo del índice IPSA:

$$(\bar{R}_{it} - R_{ft}) = \alpha_i + \beta_i(\bar{R}_{mt} - R_{ft}) + \varepsilon_{it} \quad 2.16$$

Paso 3: Se clasifican las acciones de acuerdo con sus betas estimadas (del segundo paso) y se construyen 10 carteras de acciones ponderadas equitativamente: Específicamente la primera cartera contiene acciones con el mayor valor de las betas (riesgo sistemático) y la décima cartera contiene las acciones con el valor más bajo de riesgo sistemático (Beta). Utilizamos esta técnica para reducir el problema del error en variables (EIV) que surge en la previsión de precios de activos (Fama, Eugene; MacBeth, James, 1973)

Paso 4: Para el próximo año del período considerado en la investigación, se estiman los rendimientos de las carteras para cada uno de los doce meses promediando los retornos excesivos de las acciones realizadas de cada cartera:

$$R_{kt} = \frac{\sum_{it}^n R_{it}}{N} \quad 2.17$$

Donde:

R_{kt} : Exceso de retorno de un K portafolio en el tiempo t, R_{it} : Exceso de retornos de una acción i en el tiempo t, N: El número de acciones del portafolio.

Paso 5: Los pasos 1 a 4 se repiten hasta que se construyan las series temporales necesarias de los retornos excesivos de las acciones y carteras para todos los períodos.

Paso 6: Para todo el período de estimación, que es de diez años y para los tres subperíodos, se calcula la media mensual de los retornos, para cada una de las diez carteras:

$$R_{kt} = \frac{\sum_{it}^n R_{it}}{N} \quad 2.18$$

Y el coeficiente beta para cada uno de los 10 portafolios

$$\bar{R}_K = \alpha_k + \beta_k R_{Mt} + \varepsilon_{Kt} \quad 2.19$$

Paso 7.- El portafolio se conformará de nuevo y sus rendimientos se procesarán para el año 2011 y así sucesivamente hasta el último periodo que corresponde a diciembre de 2017.

Paso 8. Las betas de las carteras se estiman mediante regresiones sucesivas calculadas en los pasos 3, 5 y 7 para el índice de mercado. La ecuación de regresión es:

$$R_{pt} = \alpha_p + \beta_p R_{Mt} + \varepsilon_{pt} \quad 2.20$$

Donde:

R_{pt} : Corresponde al exceso de retorno del portafolio sobre la tasa libre de riesgo en el periodo t, α_p : Intercepto de regresión, β_p : Beta estimado del portafolio p, R_{Mt} : Exceso de retorno del mercado sobre la tasa libre de riesgo en el periodo t, ε_{pt} : Término del error aleatorio de la estimación.

Paso 9.- La regresión "Cross - Sectional" se realizará para estimar la línea SML mediante la regresión de portafolios promedio de los retornos sobre la tasa libre de riesgo en el periodo de 2008 a 2017 de acuerdo con los valores de regresión estimados en el paso 8. La ecuación de la regresión es:

$$R_{pt} = \gamma_0 + \gamma_1 \beta_p + \varepsilon_{pt} \quad 2.21$$

Donde:

R_{pt} : Corresponde al exceso de retorno del portafolio sobre la tasa libre de riesgo en el periodo t , γ_0 : Intercepto de la regresión, γ_1 : Coeficiente de la regresión, β_i : Beta estimado del portafolio p -ésimo, ε_{it} : Término del error aleatorio de la estimación.

Paso 10.- Las hipótesis de no linealidad y de no riesgo sistemático serán testeadas con las siguientes ecuaciones:

$$R_{pt} = \gamma_0 + \gamma_1\beta_p + \gamma_2\beta_p^2 + \varepsilon_{pt} \quad 2.22$$

$$R_{pt} = \gamma_0 + \gamma_1\beta_p + \gamma_2\beta_p^2 + \gamma_3S(\varepsilon)_p + \varepsilon_{pt} \quad 2.23$$

2.5.7.-Test Black, Jensen, and Scholes – Fama Macbeth

Esta prueba fue realizada con los activos de la Bolsa de Valores de Nueva York, y dio como resultado que las carteras eran eficientes y el proxy de mercado adecuadamente eficiente. No se rechazaron las hipótesis de que los rendimientos de los activos reflejaban el actuar de los inversores para evitar el riesgo según sus rendimientos; por lo tanto, conforman en promedio carteras eficientes.

También se evidenció la compensación positiva entre el riesgo y retorno. No se pudo rechazar la no linealidad de los retornos, por lo que el modelo CAPM aplica para la valoración de los activos. Así mismo se detectó que el riesgo de cartera afecta sistemáticamente los rendimientos, además las propiedades que se observan del “Fair Game” se cumplen, ya que los valores reflejaban completamente la información disponible. (Fama, Eugene; MacBeth, James, 1973)

Este test es muy similar al anterior, también se utiliza la construcción de portafolios; sin embargo, a diferencia del proceso BJS, se conforman los portafolios una sola vez, por lo que siempre serán los mismos durante todo el proceso de pruebas y este considera los siguientes pasos:

Paso 1.- El riesgo sistemático de los activos se realiza utilizando la ecuación (2.8), de acuerdo con el exceso de los retornos de los años 2007 y 2008.

Paso 2.- Se clasificarán las acciones por el resultado de su riesgo sistemático estimado en el paso 1, del cual se crearán diez portafolios, el 5% de las betas más

altas compondrán el primer portafolio y así sucesivamente, hasta conformar 20 portafolios.

Paso 3.- Los rendimientos mensuales de estos portafolios se procesarán en los años 2008-2011 como un promedio aritmético del exceso de retornos mensuales de las acciones del portafolio.

Paso 4.- El riesgo sistemático se estimará utilizando la ecuación (2.15), de acuerdo al exceso de rendimiento mensual de los años 2008 - 2011.-

Paso 5.- Se utilizará una regresión "Cross-Sectional", utilizando la ecuación (2.16), para estimar la SML, con los valores estimados en el proceso del punto 4.

Paso 6.- La prueba de hipótesis de linealidad y de riesgo sistemático se obtendrá aplicando las ecuaciones (2.22) y (2.23).

Es necesario revisar las críticas a estas pruebas que surgieron tempranamente. Una de ellas menciona que la única hipótesis comprobable del modelo de dos parámetros es la de cartera de mercado de media varianza eficiente. Además, se deben considerar todos los activos del mercado para evaluar una contrastación de su validez.

De este modo, sustituir la cartera por un proxy de mercado (índice), no solo no permitirá colocar a prueba la teoría del CAPM, también se puede incurrir en errores en la estimación del riesgo del mercado. No considerar este aspecto puede llevar al error más grave en la valoración de activos que es la sub o sobre valoración del riesgo. A modo de ejemplo, si un mercado de un total de 1.000 activos, se eligen para realizar un análisis una muestra de 500 activos representativos y eficientes, obteniendo que los retornos y su relación con el estimador de riesgo sistemático (Beta) sea exactamente lineal, se incurre en un error, debido a que es común que los activos mayormente representativos puedan contener una alta correlación entre ellos (Roll, Richard, 1977).

Si bien aplica la teoría de test de corte transversal, este estudio aborda esta crítica de la siguiente forma: debido a las características del mercado chileno que es pequeño, se utilizan todos los activos que componen el índice y, en segundo lugar, se determinará por la prueba de estacionariedad, si el índice IPSA se puede considerar como eficiente de media y varianza constante, por lo que se probará la eficiencia en precios y retornos.


2.5.8.-Datos utilizados

En 1893, la Bolsa de Santiago inició sus actividades para conformar un mercado de valores para Chile que funciona hasta el día de hoy.

Uno de sus mercados actuales es el accionario cuyos datos utilizaremos para el estudio de las metodologías antes descritas. Este mercado durante el año 2017 registró transacciones totales por US\$ 37.535 millones de dólares, anotando un aumento de 38,2% respecto al volumen de negocios registrado el año anterior.

La bolsa posee dos índices: IGPA (Índice General de Precios de Acciones) e IPSA (Índice de Precios Selectivo de Acciones). En la figura 9, se muestra el monto total de las transacciones por año, de acuerdo con el período de estudio y en la figura 10, se muestra la evolución mensual del precio del índice en el mismo periodo.

Figura 2.9: Monto de transacciones Índice IPSA



Fuente: Elaboración Propia: Datos: Bolsa de Valores de Santiago de Chile

Figura 2.10: Evolución de precio del Índice IPSA

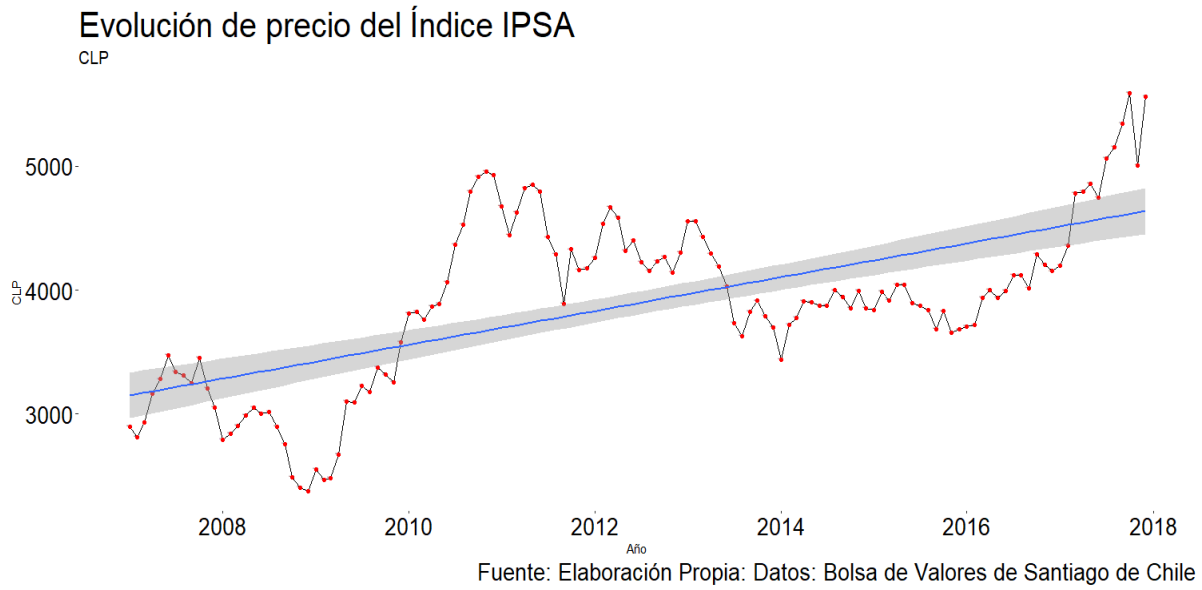



Figura 2.11: Evolución de Retorno del Índice IPSA



Este estudio utilizará los precios de acciones del índice IPSA cuyos activos se muestran a continuación. Los precios que se utilizan son mensuales y comprenden los periodos de enero 2007 a diciembre de 2017.

Nemotécnico	Industria	Nemotécnico	Industria
BCI	Banca	SM-CHILE B	Holding
BSANTANDER	Banca	MASISA	Industrial
CHILE	Banca	SK	Industrial
ITAU CORP	Banca	SMSAAM	Industrial
SECURITY	Banca	VAPORES	Industrial
CAP	Commodities	CENCOSUD	Retail

CMPC	Commodities	FALABELLA	Retail
COPEC	Commodities	FORUS	Retail
SQM-B	Commodities	NUEVAPOLAR	Retail
BESALCO	Const. E Inmob.	RIPLEY	Retail
PARAUCO	Const. E Inmob	SONDA	TI
SALFACORP	Const. E Inmob	ENTEL	Telecomunicaciones
ANDINA-B	Consumo	LTM	Transporte Aéreo
CCU	Consumo	AESGENER	Utilities
CONCHATORO	Consumo	AGUAS-A	Utilities
EMBONOR-B	Consumo	COLBUN	Utilities
ANTARCHILE	Holding	ECL	Utilities
IAM	Holding	ENELAM	Utilities
ILC	Holding	ENELCHILE	Utilities

Tabla 2.1: Acciones que componen el IPSA por Industria

Acción	Media	Error típico	Mediana	Desv. Std	Varianza	Curtosis	Meses
IPSA	0,023%	0,020%	0,044%	0,0104	0,0001	11,42	2.742
AESGENER	-0,002%	0,029%	-0,006%	0,0153	0,0002	4,27	2.742
ANDINA-B	0,022%	0,031%	-0,006%	0,0164	0,0003	5,04	2.742
BCI	0,038%	0,029%	-0,006%	0,0149	0,0002	3,00	2.742
BSANTANDER	0,020%	0,031%	-0,006%	0,0161	0,0003	4,88	2.742
CAP	-0,004%	0,051%	-0,022%	0,0268	0,0007	5,99	2.742
CCU	0,035%	0,029%	-0,003%	0,0150	0,0002	2,95	2.742
CENCOSUD	0,000%	0,034%	-0,026%	0,0179	0,0003	5,87	2.742
CHILE	0,031%	0,025%	0,011%	0,0133	0,0002	14,70	2.742
CMPC	0,005%	0,031%	-0,026%	0,0164	0,0003	2,58	2.742
COLBUN	0,008%	0,027%	-0,011%	0,0140	0,0002	2,84	2.742
CONCHATORO	0,010%	0,029%	-0,006%	0,0150	0,0002	3,36	2.742
COPEC	0,010%	0,029%	0,000%	0,0152	0,0002	3,17	2.742
ECL	0,042%	0,032%	-0,012%	0,0166	0,0003	5,46	2.742
ENELAM	-0,011%	0,034%	-0,005%	0,0177	0,0003	208,24	2.742
ENELGXCH	0,022%	0,032%	-0,026%	0,0166	0,0003	350,72	2.742
ENTEL	0,002%	0,027%	-0,023%	0,0142	0,0002	2,90	2.742
FALABELLA	0,040%	0,030%	-0,006%	0,0159	0,0003	3,07	2.742
IAM	0,017%	0,025%	-0,006%	0,0131	0,0002	15,98	2.742
ITAUCORP	0,021%	0,029%	-0,006%	0,0151	0,0002	7,37	2.742
LTM	0,009%	0,035%	-0,051%	0,0182	0,0003	3,41	2.742
MASISA	-0,032%	0,040%	-0,005%	0,0211	0,0004	5,24	2.742
NUEVAPOLAR	-0,100%	0,072%	-0,157%	0,0376	0,0014	27,33	2.742
RIPLEY	-0,003%	0,038%	-0,063%	0,0196	0,0004	27,44	2.742
SONDA	0,020%	0,030%	-0,006%	0,0156	0,0002	5,16	2.742
SQM-B	0,056%	0,044%	0,017%	0,0231	0,0005	9,39	2.742
VAPORES	-0,094%	0,053%	-0,115%	0,0278	0,0008	169,96	2.742

Tabla 2.2: Estadístico descriptivo de los retornos de las acciones que componen el IPSA por mes, utilizado en este estudio.

El tiempo del periodo en estudio de precios presentes en la bolsa de valores de Santiago durante 2007 y 2017, comprende 132 meses.

La elección de la periodicidad de los precios puede afectar a las estimaciones del riesgo sistemático (β), que es el intervalo del retorno utilizado para medir retornos históricamente. Los rendimientos se pueden medir diaria, semanal, mensual, trimestral o anualmente. De hecho, con datos sobre transacciones intradía, los rendimientos pueden incluso medirse utilizando intervalos tan cortos como quince minutos.

El uso de la frecuencia de los datos de retornos más cortos aumenta el número de observaciones de la regresión, pero tiene un inconveniente: debido a que los activos no se negocian en forma continua y cuando no hay negociación en el activo, el estimador del riesgo sistemático puede verse afectado. En particular, la no negociación de un activo durante un periodo de retorno puede reducir la correlación medida con el índice de mercado y, en consecuencia, la estimación beta midiendo erróneamente el riesgo sistemático.

El problema de periodos de no negociación de activos puede plantearse de dos formas, primero con la utilización de periodos más largos (trimestrales, anuales), pero tiene el inconveniente en la reducción en el número de observaciones para la regresión, por lo tanto es aconsejable utilizar periodos mensuales, debido a que por un lado proporcionan observaciones suficientes para las empresas, y además elimina el sesgo de los valores diarios y semanales, los cuales presentan en muchos casos tiempos que no se negocian los activos, ya que al considerar empresas sin liquidez, en periodos cortos, estos pueden subestimar el estimador beta de lo que realmente se debe considerar como riesgo. (Damodaran, 2002).

Los precios que se utilizarán en esta investigación son mensuales, para evitar variabilidades específicas en días de cierre de la bolsa para los sectores económicos que componen en IPSA.


2.6.-Resultados

Análisis del resultado de estacionariedad

La revisión del precio del índice IPSA indica lo siguiente:

De acuerdo con la figura 2.12, la evolución de precios muestra que la serie tiene tendencia, esto significa que esta no es estacionaria. Ello implica que con esta simple observación la serie no cumpliría con: media cero y varianza y covarianza constantes. Sin embargo, se debe considerar como una apreciación a priori válida, pero que debe ser apoyada por medio del test de raíces unitarias.

Figura 2.12: Correlograma IPSA, Elaboración Propia. Software utilizado Eviews.



Null Hypothesis: IPSA has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*		
Augmented Dickey-Fuller test statistic	-0.826980	0.8078		
Test critical values:				
1% level	-3.480818			
5% level	-2.883579			
10% level	-2.578601			
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(IPSA)				
Method: Least Squares				
Date: 08/12/18 Time: 11:24				
Sample (adjusted): 2007M02 2017M12				
Included observations: 131 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
IPSA(-1)	-0.018939	0.022901	-0.826980	0.4098
C	93.86900	90.21209	1.040537	0.3000
R-squared	0.005274	Mean dependent var	20.37649	
Adjusted R-squared	-0.002438	S.D. dependent var	177.3176	
S.E. of regression	177.5336	Akaike info criterion	13.21135	
Sum squared resid	4065845	Schwarz criterion	13.25524	
Log likelihood	-863.3432	Hannan-Quinn criter.	13.22918	
F-statistic	0.683895	Durbin-Watson stat	1.903397	
Prob(F-statistic)	0.409776			

Tabla 2.3: Test DF con Drift y sin tendencia determinística. Software utilizado Eviews.

La figura 2.12, muestra un patrón del modelo de caminata aleatoria. Los coeficientes de auto correlación son muy altos en toda la muestra.

Este correlograma corresponde a una serie de tiempo no estacionaria que comienza con coeficientes de rezago bastante altos y que van disminuyendo muy lentamente, lo que se conoce como series con memoria lenta.

Test Dickey-Fuller con drift (intercepto) y sin tendencia determinística.

$H_0 : d_1 = 0$ Tiene Raíz unitaria y no estacionariedad.

$H_1 : d_1 < 0$ No tiene Raíz unitaria y estacionaria.

En la tabla 1 se puede observar p-value da un valor de $0,8078 > 0,05$ por lo tanto, no se rechaza la hipótesis nula al 1%, al 5% y al 10%. Entonces no se puede concluir que no tiene raíz unitaria, entregando como resultado que la serie de precios del IPSA (2007-2017) no es estacionaria.

El test de estacionariedad se realizó a todas las acciones que componen el índice IPSA. Solo el precio de una acción (Concha Y Toro) se comporta como estacionaria en el periodo de 2007 a 2017 (Ver Tabla D, Anexo A),

Test Dickey-Fuller sin drift (intercepto) y sin tendencia determinística y Test D-F con drift y con tendencia determinística.

Null Hypothesis: IPSA has a unit root
Exogenous: None
Lag Length: 0 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	1.151542	0.9352
Test critical values:		
1% level	-2.582734	
5% level	-1.943285	
10% level	-1.615099	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(IPSA)
Method: Least Squares
Date: 08/19/18 Time: 13:55
Sample (adjusted): 2007M02 2017M12
Included observations: 131 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
IPSA(-1)	0.004536	0.003939	1.151542	0.2516
R-squared	-0.003075	Mean dependent var		20.37649
Adjusted R-squared	-0.003075	S.D. dependent var		177.3176
S.E. of regression	177.5901	Akaike info criterion		13.20444
Sum squared resid	4099970.	Schwarz criterion		13.22639
Log likelihood	-863.8906	Hannan-Quinn criter.		13.21336
Durbin-Watson stat	1.930599			

Tabla 2.4: Test DF Sin drift y sin tendencia determinística. Software utilizado Eviews.

Null Hypothesis: IPSA has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.508987	0.8218
Test critical values:		
1% level	-4.029595	
5% level	-3.444487	
10% level	-3.147063	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(IPSA)
Method: Least Squares
Date: 08/19/18 Time: 14:09
Sample (adjusted): 2007M02 2017M12
Included observations: 131 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
IPSA(-1)	-0.043743	0.028988	-1.508987	0.1338
C	142.5739	96.50114	1.477432	0.1420
@TREND("2007M01")	0.720390	0.519201	1.387498	0.1677
R-squared	0.020013	Mean dependent var		20.37649
Adjusted R-squared	0.004700	S.D. dependent var		177.3176
S.E. of regression	176.9004	Akaike info criterion		13.21169
Sum squared resid	4005600.	Schwarz criterion		13.27753
Log likelihood	-862.3654	Hannan-Quinn criter.		13.23844
F-statistic	1.306975	Durbin-Watson stat		1.886368
Prob(F-statistic)	0.274224			

Tabla 2.5: Test DF con drift y con tendencia determinística. Software utilizado Eviews.

..

En la tabla 2.3, se puede observar que p-value da un valor de $0,9352 > 0,05$ por lo tanto, no se rechaza la hipótesis nula al 1%, al 5% y al 10%. Por lo que se concluye que la serie de datos (precios IPSA), no es estacionaria. Del mismo modo se rechaza la hipótesis nula del test DF con drift y tendencia determinística ($0,8218 > 0,05$), indicando que la serie es no estacionaria.

La revisión del precio del retorno del periodo estudiado del índice IPSA indica lo siguiente:

De acuerdo con la figura 2.13, la evolución de retornos del IPSA no tiene tendencia, esto significa que la serie es estacionaria de acuerdo con el análisis gráfico. Para confirmar esta primera apreciación se aplicarán los test de raíz unitaria.

Figura 2.13: Correlograma Retorno IPSA,
Elaboración Propia. Software utilizado

Eviews.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.066	0.066	0.5919	0.442
		2 0.079	0.075	1.4366	0.488
		3 -0.095	-0.106	2.6576	0.447
		4 0.037	0.045	2.8484	0.584
		5 0.024	0.035	2.9300	0.711
		6 -0.033	-0.055	3.0786	0.799
		7 -0.070	-0.062	3.7630	0.807
		8 0.003	0.025	3.7641	0.878
		9 0.076	0.076	4.5946	0.868
		10 0.021	-0.004	4.6571	0.913
		11 0.126	0.126	6.9570	0.803
		12 0.026	0.027	7.0590	0.854
		13 -0.099	-0.142	8.5021	0.809
		14 0.063	0.099	9.1008	0.825
		15 0.025	0.042	9.1964	0.867
		16 -0.133	-0.197	11.865	0.753
		17 -0.083	-0.031	12.906	0.742
		18 -0.051	0.024	13.315	0.773
		19 -0.021	-0.080	13.386	0.818
		20 -0.070	-0.108	14.161	0.822
		21 -0.101	-0.045	15.779	0.782
		22 -0.048	-0.039	16.148	0.808
		23 0.018	-0.038	16.200	0.847
		24 -0.044	-0.018	16.511	0.869
		25 -0.005	0.014	16.516	0.899
		26 0.027	0.001	16.633	0.920
		27 -0.035	0.002	16.836	0.935
		28 0.030	0.071	16.987	0.949
		29 0.064	0.051	17.697	0.950
		30 0.035	0.043	17.909	0.960
		31 -0.127	-0.101	20.714	0.919
		32 -0.056	-0.027	21.266	0.926
		33 -0.003	0.025	21.268	0.943
		34 -0.001	-0.061	21.268	0.956
		35 0.030	0.044	21.433	0.965
		36 -0.053	-0.040	21.956	0.968

Null Hypothesis: RETORNO_IPSA has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-10.37134	0.0000
Test critical values:		
1% level	-3.481217	
5% level	-2.883753	
10% level	-2.578694	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(RETORNO_IPSA)
Method: Least Squares
Date: 12/09/18 Time: 18:06
Sample (adjusted): 2007M03 2017M12
Included observations: 130 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RETORNO_IPSA(-1)	-0.930761	0.089744	-10.37134	0.0000
C	0.004960	0.004005	1.238481	0.2178
R-squared	0.456625	Mean dependent var		0.001043
Adjusted R-squared	0.452380	S.D. dependent var		0.061429
S.E. of regression	0.045459	Akaike info criterion		-3.328761
Sum squared resid	0.264511	Schwarz criterion		-3.284645
Log likelihood	218.3695	Hannan-Quinn criter.		-3.310836
F-statistic	107.5647	Durbin-Watson stat		1.949673
Prob(F-statistic)	0.000000			

Tabla 2.6: Test DF con Drift y sin tendencia
determinística. Software utilizado Eviews.

Null Hypothesis: RETORNO_IPSA has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-10.33205	0.0000
Test critical values:		
1% level	-4.030157	
5% level	-3.444756	
10% level	-3.147221	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(RETORNO_IPSA)
Method: Least Squares
Date: 12/09/18 Time: 18:29
Sample (adjusted): 2007M03 2017M12
Included observations: 130 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RETORNO_IPSA(-1)	-0.930726	0.090081	-10.33205	0.0000
C	0.003526	0.008060	0.437496	0.6625
@TREND("2007M02")	2.19E-05	0.000107	0.205230	0.8377
R-squared	0.456805	Mean dependent var		0.001043
Adjusted R-squared	0.448251	S.D. dependent var		0.061429
S.E. of regression	0.045630	Akaike info criterion		-3.313708
Sum squared resid	0.264423	Schwarz criterion		-3.247535
Log likelihood	218.3910	Hannan-Quinn criter.		-3.286820
F-statistic	53.40094	Durbin-Watson stat		1.950377
Prob(F-statistic)	0.000000			

Tabla 2.7: Test DF con drift y con tendencia
determinística. Software utilizado Eviews.

Null Hypothesis: RETORNO_IPSA has a unit root
Exogenous: None
Lag Length: 0 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-10.27921	0.0000
Test critical values:		
1% level	-2.582872	
5% level	-1.943304	
10% level	-1.615087	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(RETORNO_IPSA)
Method: Least Squares
Date: 12/09/18 Time: 18:32
Sample (adjusted): 2007M03 2017M12
Included observations: 130 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RETORNO_IPSA(-1)	-0.920281	0.089528	-10.27921	0.0000
R-squared	0.450114	Mean dependent var		0.001043
Adjusted R-squared	0.450114	S.D. dependent var		0.061429
S.E. of regression	0.045553	Akaike info criterion		-3.332234
Sum squared resid	0.267680	Schwarz criterion		-3.310176
Log likelihood	217.5952	Hannan-Quinn criter.		-3.323271
Durbin-Watson stat	1.947021			

Tabla 2.8: Test DF Sin drift y sin tendencia
determinística. Software utilizado Eviews.


En las tablas 2.5, 2.6 y 2.7, el p-value es de 0.0000, por lo que $0,0000 < 0,05$, no rechaza la hipótesis nula, por esta razón según el test y análisis gráfico, los

retornos del IPSA se comportan como una serie estacionaria, es decir con media y varianza constantes.

Test al modelo CAPM

La regresión en dos etapas dio como resultado los siguientes datos estadísticos que pueden visualizarse en la Tabla A, Anexo A:

Figura 2.14: SML de todos los retornos de Acciones del IPSA, entre 2007 -2017. Software utilizado Rstudio.



La SML (Security Market Line) o Línea de Mercado de Valores, es la siguiente:

La figura 2.14, muestra la representación gráfica de la línea de mercado estimada de la bolsa de comercio de Santiago de Chile índice IPSA. La intersección de las líneas no es cero y muestra una pendiente descendente lo que es contraria a la teoría financiera y/o del modelo CAPM, donde se establece en que la relación riesgo retorno es positiva. Para realizar una revisión más exhaustiva, se debe ver el resultado en la aplicación de la ecuación (2.11):

	Resultados de Regresión	T-Value	P-Value
Y_0	0,0081	2,5302	0,0157
Y_1	-0,0051	-1,7362	0,0906
R^2	7,35%		
Error Estándar	0,0767		

Tabla 2.9: Resultado de regresión de dos etapas (Ecuación 12).

De la tabla 2.8, se obtiene que γ_0 (H_1 : Si $\hat{\gamma}_0 = R_f$), es distinto que cero con un P-Value menor al 5%, lo que indica que el resultado es estadísticamente significativo. Por lo tanto, no es compatible con el CAPM, donde indica que γ_0 corresponde al valor del activo libre de riesgo. En el periodo de estudio en promedio del activo libre de riesgo es de: 0,0013, con respecto γ_1 , es negativo, por lo que no existe relación positiva entre riesgo y retorno, pero no posee una significancia estadística al 5%. El R^2 es pequeño, lo que indicaría que solo una pequeña variación en los rendimientos de las acciones puede ser explicado por el riesgo sistemático (β).

Contraste de hipótesis de linealidad

	Resultados de Regresión	T-Value	P-Value
γ_0	-0,0006	-0,0892	0,9294
γ_1	0,0136	1,1277	0,2667
γ_2	-0,0086	-1,6019	0,1177
R^2	13,36%		

Tabla 2.10: Resultado de regresión de dos etapas (Ecuación 13).

La constante γ_0 es distinta de cero, pero no es estadísticamente significativa al 5%; por lo tanto, no es concluyente al igual que los estimadores γ_1 e γ_2 . El R^2 es pequeño, por lo que indicaría que solo una pequeña variación en los rendimientos de las acciones puede ser explicada por el riesgo sistemático (β).

Contraste de Hipótesis de Riesgo Sistemático

	Resultados de Regresión	T-Value	P-Value
γ_0	-0,0009	-0,1819	0,8567
γ_1	0,0161	1,6187	0,1142
γ_2	-0,0066	-1,4843	0,1464
γ_3	-0,9305	-4,2971	0,0001
R^2	42,73%		
Error Estándar	0,0062		


Tabla 2.11: Resultado de regresión de dos etapas (Ecuación 14).

La constante γ_0 y los estimadores γ_1 e γ_2 , no son estadísticamente significativos al 5%. El estimador γ_3 es significativo; por lo tanto, se rechaza la hipótesis H_4 : Si $\hat{\gamma}_3 = 0$, sólo β_p , (riesgo sistemático) no es cero; por consiguiente, indica que

existen más factores de riesgo que no están considerados en el riesgo sistemático que considera el modelo CAPM para este mercado.

El test BJS dio como resultado los siguientes datos estadísticos, que pueden visualizarse en la Tabla B.

Figura 2.15: SML de todos los retornos de Acciones del IPSA, entre 2007 -2017 (10 Portafolios).
Software utilizado Rstudio.



Las figuras 2.15 y 14, muestran que la relación entre riesgo y retorno no es una pendiente positiva. Tampoco la intercepción comienza desde cero, indicando que no es consistente con la teoría financiera en el sentido que, a mayor riesgo, mayor retorno.

	Resultados de Regresión	T-Value	P-Value
γ_0	0,0071	1,6102	0,1460
γ_1	-0,0040	-0,9639	0,3633
R^2	10,41%		
Error Estándar	0,0057		

Tabla 2.12: Resultado de regresión BJS (Ecuación 12).

Tanto los estimadores γ_0 e γ_1 no son estadísticamente significativos al 5%, por lo que no se puede concluir en esta etapa del test BJS.

Contraste de hipótesis de linealidad

	Resultados de Regresión	T-Value	P-Value
γ_0	-0,0066	-1,0302	0,3372
γ_1	0,0288	2,1526	0,0684
γ_2	-0,0160	-2,5238	0,0396
R^2	53,09%		
Error Estándar	0,0044		

Tabla 2.13: Resultado de regresión BJS (Ecuación 13).

Los estimadores γ_0 e γ_1 (tabla 2.12), no son estadísticamente significativos al 5%, por lo que no se puede concluir en esta etapa del test BJS. Sin embargo, el estimador γ_2 es significativo estadísticamente, lo que implica que no se cumple la hipótesis H_3 : Si $\hat{\gamma}_2 = 0$; por tanto, no existe una relación lineal entre los retornos y el riesgo sistemático (β).

Contraste de Hipótesis de Riesgo Sistemático


	Resultados de Regresión	T-Value	P-Value
γ_0	0,0519	2,6662	0,0372
γ_1	-0,0962	-2,3167	0,0597
γ_2	0,0492	2,2827	0,0626
γ_3	-3807,6070	-3,0839	0,0216
R^2	81,85%		
Error Estándar	0,0030		

Tabla 2.14: Resultado de regresión BJS (Ecuación 14).

De acuerdo con la tabla 2.13. Los estimadores γ_1 e γ_2 no son estadísticamente significativos al 5%, por lo que no se puede rechazar las hipótesis con respecto a estos estimadores. No obstante, el estimador γ_0 es significativo, lo que implica que no se cumple la hipótesis H_1 : Si $\hat{\gamma}_0 = 0$. Por consiguiente, el intercepto no corresponde al activo libre de riesgo en el mercado y el estimador $\hat{\gamma}_3$ es distinto a cero. Esto indica que existen más factores de riesgo que no están considerados en el riesgo sistemático que considera el modelo CAPM para este mercado.

El test BJS-FM dio como resultado los siguientes datos estadísticos, que pueden visualizarse en la Tabla C.

Figura 2.16: SML de todos los retornos de Acciones del IPSA, entre 2007 -2017 (20 Portafolios). .
Software utilizado Rstudio.



Fuente: Elaboración Propia

Las figuras 2.16, 2.14 y 2.15, muestran que la relación entre riesgo y retorno no es una pendiente positiva. Tampoco la intercepción comienza desde cero, indicando que no es consistente con la teoría financiera en el sentido que, a mayor riesgo, mayor retorno.

	Resultados de Regresión	T-Value	P-Value
γ_0	0,0040	1,8725	0,0775
γ_1	-0,0037	-2,0514	0,0551
R^2	18,95%		
Error Estándar	0,0032		

Tabla 2.15: Resultado de regresión BJS-FM (Ecuación 12).

La tabla 2.14 muestra que si bien el valor del intercepto $\hat{\gamma}_0$ es inconsistente con la teoría del CAPM, ya que es distinto de cero, no es concluyente al no presentar significancia estadística (P-Value > 5%). Con respecto al estimador γ_1 , es negativo, por lo que no existe relación positiva entre riesgo y retorno, en este caso presenta significancia estadística en torno al 5%. Revisando el coeficiente de determinación (R^2), es de 18,95% bastante bajo, por lo que indica que no existe una relación clara entre los retornos y el riesgo sistemático, indicando que faltan factores de riesgo en el modelo analizado.

Contraste de hipótesis de linealidad

	Resultados de Regresión	T-Value	P-Value
γ_0	0,0027	0,3682	0,7173
γ_1	-0,0014	-0,1160	0,9090
γ_2	-0,0009	-0,1897	0,8518
R^2	19,12%		

Tabla 2.16: Resultado de regresión BJS-FM (Ecuación 13).

La tabla 2.15 muestra que la constante γ_0 , es distinta de cero, pero no es estadísticamente significativa al 5%, por lo tanto; no es concluyente, al igual que los estimadores γ_1 e γ_2 . El R^2 , es pequeño por lo que indicaría que solo una pequeña variación en los rendimientos de las acciones puede ser explicado por el riesgo sistemático (β).

Contraste de Hipótesis de Riesgo Sistemático

	Resultados de Regresión	T-Value	P-Value
γ_0	0,0005	0,0941	0,9262
γ_1	0,0040	0,4381	0,6672
γ_2	-0,0016	-0,4771	0,6398
γ_3	-1,1254	-4,0179	0,0010
R^2	59,74%		
Error Estándar	0,0024		

Tabla 2.17: Resultado de regresión BJS-FM (Ecuación 14).

De acuerdo con la tabla 2.16, tanto los estimadores γ_1, γ_2 e γ_2 no son estadísticamente significativos al 5%, por lo que no se puede concluir que el resultado de este test sea concluyente, ya que no obtienen significancia estadística. Sin embargo, el estimador $\hat{\gamma}_3$ es distinto a cero, indicando que existen más factores de riesgo que no están considerados en el riesgo sistemático que considera el modelo CAPM para este mercado.

2.7.-Conclusiones del capítulo

Con respecto al test de estacionariedad aplicado a los precios mensuales en el periodo analizado, solo el activo financiero de “Concha y Toro” es estacionario.

Los demás treinta y nueve títulos de acciones (ver tabla D, Anexo A) indican que sus series de precios no son estacionarias, prueba realizada con intercepto y un rezago AR (1). Además, fue sometido a la misma prueba el índice que agrupa a los activos (IPSA), que también rechazó la hipótesis nula, por lo tanto, el IPSA posee un comportamiento aleatorio en el precio.

La prueba de estacionariedad también fue aplicada a los rendimientos del índice y las acciones que lo componen. El resultado fue distinto a los precios, ya que todos los retornos resultan ser estacionarios (con raíz unitaria ver tabla E, Anexo A).

El análisis fue acerca del comportamiento de caminata aleatoria (con un rezago e intercepto) de los precios de las acciones y del índice IPSA en el periodo de enero de 2007 a diciembre de 2017, considerando precios mensuales. Este concluye que el mercado chileno se clasifica como un mercado de eficiencia débil, donde los activos financieros que están considerados en el IPSA ya cuentan con toda la información pasada. Esto implica que los inversores no pueden obtener rentabilidades superiores analizando estas series o extrapolando reglas de comportamiento de los precios, debido a que todos los actores del mercado ya sabrán explotar las mismas señales que las series de precios muestran. Por lo que, con esta forma de eficiencia de mercado: Ningún inversionista podrá conseguir un rendimiento superior al promedio y si lo llegase a lograr será producto del azar, cabe señalar que este escenario solo se da bajo la utilización del análisis técnico financiero, como es la aplicación de estos modelos de valoración, para predecir el comportamiento de los precios a futuro.

Esta conclusión aplica también a los estudios de los gráficos de precios denominados "Chartistas", que solo se basan en las tendencias de precios de los activos; sin embargo, no aplica para el análisis técnico, ya que los retornos se comportan en forma estacionaria. Este estado del mercado chileno se ha confirmado por estudios anteriores con datos comprendidos entre 1987 y 1997, la investigación comprendió la revisión de eficiencia de países emergentes latinoamericanos (Argentina, Brasil, Chile y México) obteniendo como resultado que los precios siguen un camino aleatorio, y que son, en general, eficiente en forma débil. En resumen, por lo tanto, la evidencia sugiere que los inversionistas no pueden usar información histórica para diseñar estrategias de inversión, porque los rendimientos futuros a largo plazo no dependen de los rendimientos pasados. Existen estudios que revisan la aplicación del análisis técnico versus en análisis fundamental, concluyendo que, a mayor eficiencia del mercado, pierde

validez la utilización del análisis técnico (Ojah & Karamena, 1999) (Wafi, Hassan, & Mabrouk, 2015).

Investigaciones no rechazan la eficiencia en los mercados de Argentina, Brasil, Chile y México (Karamera, 1999), mientras otros trabajos encuentran para estos mismos mercados que no hay eficiencia, aplicados en otro momento (Urrutia, 1995), por lo que resulta primordial para esta investigación establecer la forma de eficiencia del mercado en estudio.

El test a los retornos del índice resulta ser estacionario; por lo tanto, el índice es adecuado para aplicarlo como proxy en los test de validez del CAPM.

Hipótesis	Dos etapas	Test BJS	Test BJS - FM
H ₁	Rechaza	No Rechaza*	No Rechaza*
H ₂	No rechaza*	No Rechaza*	No Rechaza*
H ₃	No rechaza*	No Rechaza*	No Rechaza*
H ₄	Rechaza	Rechaza	Rechaza

* Si bien el resultado del estimador considera rechazo de las hipótesis, su baja significancia estadística determina no rechazar la hipótesis.

En los tres test del CAPM, basados en la técnica de la regresión de dos pasos: BJS, BJS-FM, la línea estimada del mercado exhibe algunas propiedades no consistentes con la teoría, debido a que la intercepción de los ejes de riesgo y rentabilidad es significativamente distinta de cero y la pendiente es inversa (negativa), este no cumple con la teoría financiera que indica que a mayor riesgo el retorno debe ser mayor. La linealidad de los datos no es clara, ya que, en que en todos los test se rechaza, pero con bajo nivel de significancia estadística. Un estudio que analiza la eficiencia de mercado, en su forma débil, frente a la crisis financiera subprime de 2008, en mercados latinoamericanos (Brasil, Colombia, Venezuela, Chile y Argentina) utilizando información comprendida entre 2003 y 2014, obtiene como hallazgo que los datos dan cuenta de la inexistencia de la relación de linealidad, rechazando la hipótesis de eficiencia de mercado. (García-Moreno, Roldán, & Daniel, 2019)

Existen estudios que indican que esta relación riesgo retorno está ausente (a mayor riesgo mayor retorno) en periodo anterior a la crisis y es negativo en la presencia de crisis financiera mundial. El estudio examinó los índices de países desarrollados como emergentes y de frontera, dentro de los países emergentes se examinó a Brasil, Chile, China, Colombia, República Checa, Egipto, Grecia, Hungría, India, Indonesia, Corea y Malasia, en un período entre junio de 2005 y

junio de 2016, donde se utilizaron cuatro proxies de riesgo, desviación estándar, semi desviación, Beta y el Beta a la baja. Encontrando que esta ruptura de la relación riesgo rendimiento puede ser un factor importante para ser utilizado como un predictor de cualquier crisis financiera venidera. (Sanjay Sehgal, 2018)

El riesgo sistemático en todos los test indica que no es el adecuado nivel de riesgo para el modelo; es decir, el análisis sugiere que faltan factores de riesgo que influyen en el riesgo sistémico (beta) en el periodo analizado en el mercado de valores chileno. Una investigación realizada con las 25 mayores empresas de la bolsa de valores de Estambul somete a validación el modelo CAPM, para verificar la relación lineal entre riesgo sistemático y el retorno de las acciones, concluyendo que no existe relación lineal entre riesgo y retorno, sugiriendo la falta de factores de riesgo en el mercado (Karakoc, 2016).

Tanto el test de dos etapas de activos individuales como los test de portafolios indican que el estimador del riesgo sistemático no es el adecuado para los periodos en estudio. Además, el análisis gráfico (SML) no sustenta el modelo CAPM, debido a que presenta una relación negativa entre riesgo y retorno.

Los próximos análisis en mercados de poco desarrollo como el chileno, se debiesen centrar en estudios de Fama y French, que observan la relación positiva, pero insignificante, entre el rendimiento de las acciones y el riesgo sistemático (β), estableciendo la hipótesis “Beta está muerta” (Fama & French, 1996) y proponiendo la aplicación de test al modelo de tres factores propuesto por Eugene Fama y French Kenneth en 1993 (Fama, Eugene; French, Kenneth, 1993).

Se debe explorar otros modelos multifactoriales como el APT (Arbitrage Pricing Theory), o estudios de efecto de “momentum” del modelo de tres factores, introducido en 1997 por Carhart (Carhart, 1997), como también el modelo de precios de activos de cinco factores propuesto en 2015, el cual introduce una medida basada en la rentabilidad de las empresas.

Otros estudios relevantes son la revisión de introducir un diferencial de acuerdo con el tamaño de las empresas. Diferencial de inversiones a activos y diferencial de rentabilidad de portafolios (Hou, Kewei; Xue, Chen; Zhang, Lu, 2014) Como también es necesario realizar el test de eventos para probar la eficiencia del mercado de valores chileno. (Rathnasekara, 2017).

**Capítulo 3 :Impacto del COVID-19 en
la Bolsa de Valores por Sector
Industrial en Chile: Una Sobrerreacción
Adversa**

3.1.-Resumen del capítulo

Este capítulo es relevante para esta tesis, ya que estudia el comportamiento del mercado chileno, con la llegada del COVID-19, bajo el interés de conocer si este mercado sometido a un estudio de eventos recoge la información acerca del primer caso confirmado de COVID-19.

Este trabajo estudia la reacción de los precios de las acciones en el mercado de valores chileno a nivel sectorial ante la llegada del COVID-19 al país. Se encarga de responder la siguiente pregunta: ¿El mercado chileno actuó de manera eficiente ante la llegada del COVID-19?. Para responder a esta pregunta, se aplica un estudio de eventos con una ventana de retornos de 10 días antes y después del evento, a los sectores industriales que conforman el IPSA (Índice de Precios Selectivo de Acciones).

Para obtener los rendimientos anormales (AR) y los rendimientos anormales acumulados (CAR) para la ventana de eventos, se utilizaron tres modelos: (1) rendimiento promedio ajustado, (2) rendimiento de mercado ajustado y (3) el modelo de mercado.

Los resultados del estudio muestran una sobrerreacción a las pérdidas del mercado, excepto en la industria de servicios públicos, provocando mayores pérdidas después del día del evento, lo que demuestra que la información tarda en incorporarse en la etapa anterior y sugiere que los precios de los activos no reflejan todos los datos disponibles en el mercado, acerca de la llegada de la pandemia al país.

Un hallazgo significativo es que la bolsa de valores chilena respondió de forma ineficiente ante la llegada de la pandemia. Esta información es de utilidad para los inversionistas en la formación de portafolios y/o estrategias de inversión con miras al largo plazo.

3.2.-Introducción

La llegada del COVID-19 afectó la volatilidad del mercado financiero que ha continuado durante todo el período de la pandemia. En comparación con los mercados desarrollados, se ha observado que la volatilidad generada por la crisis del COVID-19 ha sido mayor en Chile ([Albulescu 2021](#)).

Los mercados reaccionaron a la incertidumbre con caídas significativas, causando una interrupción en los circuitos financieros en todo el mercado hasta en cuatro momentos diferentes en 2020. Una salvaguarda detuvo las actividades comerciales durante aproximadamente 15 minutos con la esperanza de que el mercado se calmara ([Funakoshi y Hartman 2020](#)).

A diferencia de los mercados maduros, el mercado chileno se está desarrollando con un pequeño número de empresas listadas. Las organizaciones son de tamaño pequeño en comparación con las empresas que cotizan en otras bolsas de valores de los países desarrollados. La frecuencia y el número de transacciones en el mercado de valores también son menores y, en general, las grandes inversiones se concentran en unos pocos jugadores, lo que puede conducir a fallas en el mercado. Esto significa que, en el contexto internacional, el mercado chileno tiene una clasificación baja ([Hassan y Kayser 2019](#)).

Los resultados del estudio son útiles para comprender las reacciones de un mercado emergente ante una crisis global y para brindar información a los administradores involucrados en la formación de carteras.

Chile es un país donde existen pocos estudios de este tipo. Sin embargo, la trascendencia social de la evolución del mercado chileno es muy relevante. Los fondos de pensiones chilenos son de gestión privada e invierten en activos que integran el IPSA (Índice de Precios Selectivo de Acciones), juegan un papel primordial como agentes del mercado y son observados críticamente por las bajas pensiones que distribuyen las administradoras de fondos de pensiones (AFP).

Al revisar estudios recientes en las bolsas de valores, se ve una estrategia seguida por inversionistas que buscan refugio en commodities en tiempos de crisis. Un estudio aplicado en países asiáticos concluye que el oro proporcionó un fuerte refugio para China, Indonesia, Singapur y Vietnam, durante el período de estrés

pandémico (Yousaf, y otros 2021). Activos en oro, petróleo, y el MSCI World index han sido evaluados, y se ha demostrado que algunos activos reaccionan antes y otros después del inicio de la pandemia. También se llevó a cabo la identificación de los rendimientos netos de los activos tras el shock del COVID-19, con la intención de diversificar adecuadamente los activos durante una pandemia (Bouri, Cepni, y otros 2020).

Otro estudio se centró en el efecto manada de las inversiones en el surgimiento de la emergencia sanitaria. El efecto rebaño de la incertidumbre se detectó con fuerza en los mercados emergentes y las acciones europeas. El estudio sugiere que este efecto depende del estado de desarrollo del mercado. Esta investigación sobre el comportamiento de los inversores durante la pandemia de COVID-19 puede ayudar a los agentes a tomar posiciones de cobertura para mitigar las pérdidas de la crisis. Un hallazgo significativo fue que los indicadores de sentimiento de inversión podrían ser útiles para pronosticar la volatilidad en los mercados estudiados (Bouri, Demirer, y otros 2021).

Otros estudios sectoriales similares al presente trabajo se han centrado en el mercado de valores chino, donde se examinó el exceso de volatilidad y la asimetría entre los sectores industriales del mercado durante la pandemia. Los estudios encontraron un impacto asimétrico de buena volatilidad y mala volatilidad, que se intensificó durante el período de COVID-19. Estos datos serán de utilidad para los inversores y para la formación de carteras en el mercado chino, así como para la formulación de políticas públicas sectoriales (Shahzad, y otros 2021). Los investigadores también han estudiado la distribución del riesgo sistémico entre los índices bursátiles mundiales y los activos, en particular en 14 países que se han visto gravemente afectados por el brote de COVID-19.

Estos estudios mostraron una escalada debido al contagio del riesgo sistémico entre los mercados de acciones globales y los mercados de acciones individuales durante el brote de COVID-19. En concreto, los mercados desarrollados de América del Norte y Europa transmitieron un riesgo marginal extremo a los mercados de renta variable asiáticos. Esto muestra un alto grado de integración del mercado de valores en términos de riesgo extremo a la baja, lo que es útil para la gestión del riesgo de cartera para los inversores (Abuzayed, Bouri, Al-Fayoumi, & Jalkh, 2021).

El estudio fue realizado por industria, para analizar el impacto de la crisis sanitaria en Chile, con un mercado financiero pequeño con pocos participantes, bajo número de transacciones y menores niveles de capitalización. Esta investigación es fundamental para este país en desarrollo de América del Sur, donde los estudios de este tipo son escasos en comparación con los de las bolsas de valores de los países desarrollados.

La investigación es útil para la gestión de portafolios de activos por industria con el fin de mitigar el riesgo de pérdida en la formación de carteras durante las crisis. Donde por lo general los mercados poseen la forma de eficiencia débil (Fama, Eugene, 1970). Para analizar este comportamiento se utilizó un estudio de eventos de cuarenta empresas incluidas en el IPSA (Índice de Precios Selectivo Acciones), obteniendo rendimientos diarios que incluían la fecha de llegada de la pandemia a Chile. También se examina si los datos se distribuyen normalmente, además de la aplicación de pruebas no paramétricas para garantizar que el estudio tenga una base sólida. En el estudio de eventos se emplearon tres modelos para obtener retornos anormales (AR) y retornos anormales acumulados (CAR): el modelo de retorno promedio ajustado, el modelo de retorno de mercado ajustado y el modelo de mercado. Los datos cubren una ventana de 10 días, donde se obtuvieron resultados antes del primer caso de COVID en Chile, el día de la llegada del primer caso y después del primer caso de infectado en Chile. Por otro lado, se evaluó mediante la metodología de eventos la reacción y ajuste del mercado con la llegada de la pandemia a Chile. Antes de aplicar esta metodología se revisó la distribución estadística de los datos que componen el IPSA y se encontró que no se distribuyen normalmente, como es común en este tipo de datos sean más bien leptocúrticos, como lo es también en este mercado.

También se aplicaron pruebas no paramétricas a los rendimientos anormales obtenidos con los tres métodos. Se sugiere que los retornos anormales se vieron afectados por la noticia de la pandemia en la ventana antes y después del evento; Como resultado, se produjo una sobrerreacción tras el primer caso de COVID-19 en Chile, donde todas las industrias excepto el sector de servicios públicos presenta rentabilidades negativas acumuladas superiores al 10%. Se obtuvo significación estadística en el estudio realizado, respondiendo así a la pregunta de reacción y eficiencia. El mercado inicialmente sobrerreaccionó tras el evento del primer caso, lo que sugiere que no se incorporó toda la información

disponible en los precios de los activos, lo que provocó que actuara de manera ineficiente frente a la pandemia.

3.3.-Metodología y datos

El presente trabajo se basa en la metodología de estudio de eventos propuesta por (Fama, y otros 1969), (Binder 1998) y (MacKinlay 1997), donde los datos incluyen precios registrados en la bolsa de valores de Santiago, específicamente empresas listadas en el IPSA (Índice de Precios Selectivo de Acciones). Queremos analizar si hubo una reacción del mercado tras la llegada del COVID-19, considerando que el primer caso anunciado en Chile ocurrió el 3 de marzo de 2020.

El estudio del evento permite al investigador demostrar la solidez de la información o noticia que afectan al mercado y por ende al precio de las acciones. (Fama, Eugene 1991), aquí analizamos cómo responden los mercados por industria y verificamos la eficiencia de los mercados durante un brote de virus. Varios estudios han confirmado la hipótesis del mercado eficiente, mientras que otros cuestionan la supuesta racionalidad del agente del mercado (Malkiel 2003).

Un mercado financiero se considera eficiente cuando los precios de los activos reflejan toda la información relevante disponible para tomar decisiones de inversión (Fama, Eugene 1965), y ningún agente puede acceder a la información con mayor rapidez que otros; de esta forma, es imposible obtener beneficios superiores a los de otros inversores. La condición de eficiencia implica también que los agentes económicos que interactúan en un mercado financiero están en igualdad de condiciones respecto de la información; por tanto, las decisiones de inversión de los participantes en dicho mercado serán las mejores posibles. Se pueden encontrar diferentes grados de eficiencia, como se muestra a continuación:

Eficiencia débil: las decisiones se basan en precios históricos, donde se reflejan todos los precios anteriores; sin embargo, la información pasada no tiene fuerza para predecir los precios futuros de los activos y, por lo tanto, la eficiencia es baja.

Eficiencia semi fuerte: Las decisiones toman en cuenta información pública, así como precios históricos. Los valores se ajustan rápidamente cuando la información se hace pública; por lo tanto, los precios de los activos reflejan toda la información pública disponible.

Eficiencia fuerte: En esta forma de eficiencia, las decisiones incorporan tanto información previa como información privada (interna). En consecuencia, los precios reflejan precios históricos, información pública y también toda la información posible que se puede obtener utilizando análisis comerciales particulares y evaluaciones económicas.

Si cada agente del mercado se equivoca en sus estimaciones, pero estos errores son independientes, la información que cada uno tiene se resume en el valor medio, y el resultado es la mejor estimación posible del precio. De esta forma, las acciones del conjunto reflejan la información relevante, que se puede expresar de la siguiente forma:

$$E(x_{i,t-1} | \theta_t) = 0 \quad 3.3.1$$

donde el valor del error de estimación de la rentabilidad de mercado del activo i para el periodo $t + 1$ dada la información disponible θ_t es igual a cero. Esto significa que el precio se ajusta a la rentabilidad esperada según el riesgo de cada acción. En términos más simples, con la transacción de cualquier activo, el precio actual tiene un valor presente neto (VAN) igual a cero, por lo que ninguno de los participantes obtendrá rendimientos anormales en la compra o venta de acciones

Datos utilizados

Los datos utilizados se obtuvieron de la Bolsa de Comercio de Santiago, que ofrece información en línea sobre los precios y el volumen de transacciones para cada uno de los mercados integrados en ella. Para entender la estrechez de este mercado hay que tener en cuenta que en 2020 registró un volumen de transacciones por valor de USD 40.094 millones, lo que representa una caída del -10,27% respecto al volumen de negocios registrado el año anterior. La Bolsa de Comercio de Santiago produce dos índices: el IGPA (Índice General de Precios de Acciones) y el IPSA (Índice de Precios Selectivo de Acciones). Los datos empleados en el estudio incluyen cotizaciones diarias entre el 1 de enero de 2019 y el 11 de septiembre de 2020 correspondientes a activos incluidos en el selectivo IPSA de la Bolsa de Comercio de Santiago ([B. d. Chile 2021](#)).

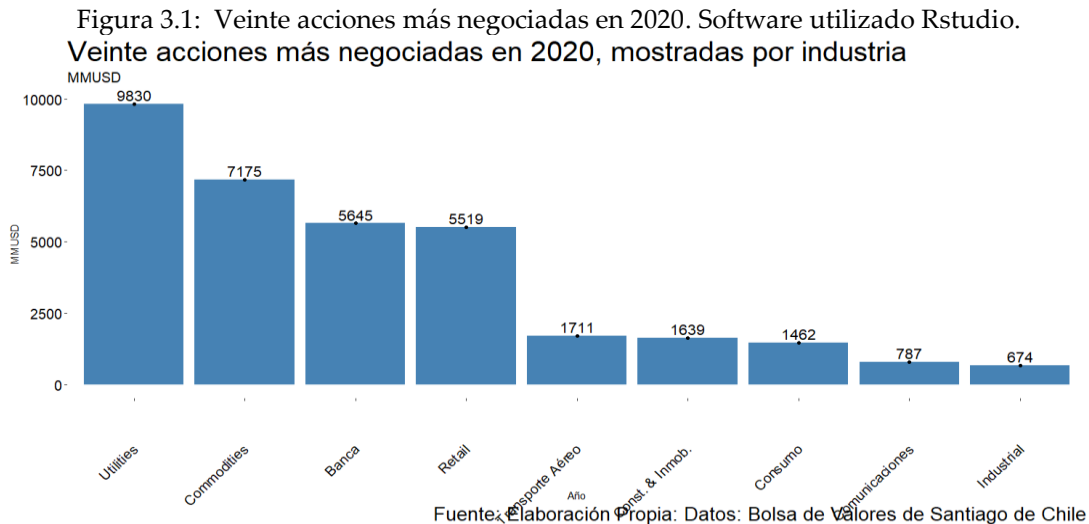
La Tabla 1 contiene los activos listados de las empresas que integran el índice IPSA y la industria a la que pertenecen. La ventana de estudio comprendió los 10

días previos y posteriores al evento de aparición del primer caso de COVID-19 en Chile.

Asset	Industry	Asset	Industry	Asset	Industry	Asset	Industry
BCI	Banking	SM-CHILE B	Holding	PARAUCO	Const. & real estate	SONDA	IT
BSANTANDER	Banking	MASISA	Industrial	SALFACORP	Const. & real estate.	ENTEL	Communica- tion
CHILE	Banking	SK	Industrial	ANDINA_B	Consumption	LTM	Air travel
ITAUCORP	Banking	SMSAAM	Industrial	CCU	Consumption	AESGENER	Utilities
SECURITY	Banking	VAPORES	Industrial	CONCHATORO	Consumption	AGUAS_A	Utilities
CAP	Commodities	CENCOSUD	Retail	EMBONOR-B	Consumption	COLBUN	Utilities
CMPC	Commodities	FALABELLA	Retail	ANTARCHILE	Holding	ECL	Utilities
COPEC	Commodities	FORUS	Retail	IAM	Holding	ENELAM	Utilities
SQMB	Commodities	NUEVAPOLAR	Retail	ILC	Holding	ENELCHILE	Utilities
BESALCO	Const. & real estate	RIPLEY	Retail	OROBLANCO	Holding	ENELGXCH	Utilities

Tabla 3.3.1: Acciones por industria del IPSA.


La tabla 3.1 muestra las veinte acciones más negociadas en 2020, agrupadas por la industria de las acciones que componen el IPSA; los cuatro sectores más importantes en 2020 fueron los servicios públicos, las materias primas, la banca y el comercio minorista.



La Figura 3.2 muestra los montos negociados en 2020; se muestran las veinte acciones que componen el IPSA, donde los cuatro activos con mayores montos negociados en 2020 corresponden a ENELAM (Enel América), SQM-B

(Soquimich, Sociedad de Química y Minería de Chile), FALABELLA (Falabella tienda) y CHILE (Banco de Chile).


Figura 3.2: Cantidad de las 20 acciones más negociadas en 2020, mostradas por industria.
Software utilizado Rstudio.



Fuente: Elaboración Propia: Datos: Bolsa de Valores de Santiago de Chile

En la Figura 3.3, se pueden observar los retornos acumulados entre las barras verticales que muestran las delimitaciones del período de estudio (antes, durante y después del evento), donde el transporte aéreo obtuvo la mayor rentabilidad negativa, seguido del comercio minorista y luego la industria de la construcción e inmobiliaria, que tuvo una menor proporción. Las industrias con la menor cantidad de caídas en los períodos de retorno acumulados fueron la industria bancaria, servicios públicos, seguidas por la industria de consumo.

Figura 3.3: Rentabilidad acumulada por industria para ventanas de 10 días antes y después del evento. Tomado de activos pertenecientes al IPSA. Fuente: Elaboración propia.



3.3.1.-Calendario de pandemia de COVID-19

En la tabla 3.2, presentamos las noticias importantes que afectaron los movimientos de los activos listados en el mercado bursátil chileno

Fecha de Evento	Noticia
31 de diciembre de 2019	La Organización Mundial de la Salud informa por primera vez que entre el 12 y el 29 de diciembre, ciertas personas que habían estado en un mercado de animales en Wuhan se infectaron con un virus desconocido. Se habla de un tipo de neumonía.
01 de enero de 2020	El mercado de Wuhan se cierra Las autoridades sanitarias chinas cerraron el mercado, justo después de que se especulara que la fuente del virus podrían ser las especies salvajes y exóticas que se comercializan allí.
07 de enero de 2020	Identificación de virus. Las autoridades de Wuhan anuncian que el virus ha sido identificado como una nueva cepa de coronavirus.
11 de enero de 2020	Primera muerte. El comisionado municipal de salud de Wuhan anuncia la primera muerte causada por el coronavirus. Un hombre de 61 años falleció por insuficiencia respiratoria.

21 de enero de 2020	<p>Primer caso reportado en los Estados Unidos.</p> <p>Las autoridades de Washington confirman a su primer paciente con COVID-19, un hombre de 30 años, que permanece en observación. Días antes, Tailandia y Japón también anunciaron sus primeros casos.</p>
30 de enero de 2020	<p>La Organización Mundial de la Salud declara emergencia sanitaria</p> <p>Horas después del anuncio de los primeros casos en los que se confirmó la transmisión entre humanos infectados fuera de China, la OMS declara el brote del virus como una emergencia de salud pública de interés internacional. En este punto, ya hay 7800 casos confirmados en 20 países de todo el mundo.</p>
04 de febrero de 2020	<p>El virus llega a los cruceros.</p> <p>El Ministerio de Salud de Japón afirma que se confirmó que 10 personas a bordo de un crucero dieron positivo por coronavirus. Un total de 3711 pasajeros se ponen en cuarentena durante más de 2 semanas. Días después, otras 700 personas se infectan.</p>
11 de febrero de 2020	<p>El nombre del virus cambió a COVID-19 y se registran más de 1000 muertes. El Comité Internacional de Taxonomía de Virus anuncia que el nuevo nombre para el actual coronavirus será coronavirus del síndrome respiratorio agudo severo tipo 2 (SARS-CoV-2), que se eligió porque está genéticamente relacionado con el brote de SARS en 2003. El director de la OMS El Dr. Tedros Adhanom anuncia que el nuevo nombre del virus será COVID-19.</p>
14 de febrero de 2020	<p>Los primeros casos de África.</p> <p>Se presenta un caso en Egipto, según información brindada por las autoridades del país, representando el primer caso confirmado dentro del continente africano.</p>
14 de febrero de 2020	<p>Comienza la crisis en Italia.</p> <p>En Europa, para evitar un brote importante de virus, varios pueblos y ciudades de Italia se bloquean. Las restricciones de circulación afectan a 100.000 personas.</p>
25 de febrero de 2020	<p>Primer caso latinoamericano.</p> <p>El Ministerio de Salud de Brasil confirma su primer infectado. Un hombre de 60 años residente en Sao Paulo que, por cuestiones de trabajo, tuvo que viajar a Italia. Días después, el virus se propaga a México, Ecuador y Argentina, entre otros países de América Latina.</p>
03 de marzo de 2020	<p>Primer caso de COVID-19 en Chile.</p> <p>Confirmado en Talca. Un médico de 33 años que había viajado al sudeste asiático; el ministerio señala que hará cuarentena en su domicilio bajo vigilancia epidemiológica.</p>
07 de marzo de 2020	<p>Se disparan los casos de infección.</p> <p>Los casos de COVID-19 en todo el mundo superan los 100.000 y las muertes más de 3400. Los cinco países con más casos confirmados son China, Corea del Sur, Irán, Italia y Japón.</p>

11 de marzo de 2020	<p>Se declara pandemia.</p> <p>La Organización Mundial de la Salud declara oficialmente el brote de COVID-19 como una pandemia. En respuesta, el presidente Donald Trump anuncia restricciones de viaje desde Europa a los Estados Unidos.</p>
14 de marzo de 2020	<p>Chile ingresa a la Etapa 3.</p> <p>La falta de trazabilidad de la infección lleva al ministerio a pasar a la tercera etapa de la pandemia, incluida la cancelación de grandes eventos para más de 500 personas, mientras que las actividades del día a día siguen disponibles, como los centros comerciales. Además, se aplica cuarentena obligatoria a los viajeros que provienen de los países pico, incluidos Japón, China, Corea, Francia, Alemania, España e Italia.</p>
15 de marzo de 2020	<p>Las escuelas se cierran y se toman otras medidas.</p> <p>Tras ingresar oficialmente a la tercera etapa, el gobierno restringe el ingreso a hogares de ancianos y también propone una ley para revisar la situación de los presos para evitar la propagación de contagios dentro de las cárceles; se declara cuarentena al interior de los domicilios del SENAME (Servicio Nacional de Menores), se establecen aduanas sanitarias en todas las fronteras y se prohíbe el ingreso de cruceros al país.</p> <p>Una de las directrices más ponderadas y controvertidas fue la de suspender los jardines de infancia por períodos de dos semanas, así como las escuelas privadas y públicas.</p>
16 de marzo de 2020	<p>Se declara la etapa 4 y cierran fronteras en todo el país</p> <p>Luego de registrar 155 casos confirmados, el gobierno inicia la etapa 4 de confinamiento y cierra las fronteras marítimas, terrestres y aéreas en todo Chile a partir del 18 de marzo. Esta resolución fue considerada luego de que otros países tomaran la misma medida, incluidos Perú y Argentina, países vecinos.</p>
21 de marzo de 2020	<p>Primera muerte en Chile.</p> <p>Una mujer de 82 años residente en la comuna de Renca se convierte en la primera víctima mortal del virus en Chile. Según información proporcionada por el ministro de Salud, Jaime Mañalich, la mujer padecía pluripatología y se encontraba físicamente colapsada, lo que explica el manejo compasivo.</p>
22 de marzo de 2020	<p>Toque de queda en Chile.</p> <p>Con más de 600 casos activos de COVID-19, el gobierno ordena restricciones a la libre circulación desde las 22:00 hasta las 05:00 de la mañana del día siguiente. Los chilenos solo pueden salir de sus casas con un permiso apropiado.</p>
Marzo de 2020	<p>Varios sectores declaran cuarentena.</p> <p>Para aplanar la curva de contagios, las autoridades imponen un confinamiento total en las siguientes comunas: Independencia, Las Condes, Lo Barnechea, Vitacura, Ñuñoa, Providencia y Santiago. Semanas después, varias otras comunas se suman a la cuarentena.</p>

30 de marzo de 2020	<p>Actas de defunción en Italia.</p> <p>A esta fecha, el país ya superó las 10.000 muertes registradas. En España, el número de víctimas mortales supera las 7300. Continúan los confinamientos en toda Europa.</p>
02 de abril de 2020	<p>Más de un millón de infectados.</p> <p>El COVID-19 ya ha infectado a más de un millón de personas en todo el mundo y ha causado 54.000 muertes hasta la fecha. Los expertos argumentan que la única forma de detener la propagación del virus es la distancia social.</p>
19 de abril de 2020	<p>La nueva normalidad de Chile.</p> <p>A través de transmisión a nivel nacional, el presidente Sebastián Piñera hace un llamado a reactivar la economía y que la fuerza laboral pública regrese paulatinamente al trabajo presencial.</p>
23 de abril de 2020	<p>Ministerio de Educación suspende regreso a clases.</p> <p>El ministro de Educación, Raúl Figueroa, anuncia que es imposible concretar una fecha para el regreso a clases debido al COVID-19. Las clases presenciales quedan suspendidas hasta que las condiciones sanitarias permitan un regreso paulatino.</p>
29 de abril de 2020	<p>Muere primer sanitario chileno.</p> <p>Autoridades de Gobierno lamentan la muerte de Lorena Durán, administrativa de Cesfam Lastarria en la Región La Araucanía, a causa del virus; ella fue la primera funcionaria dentro del sistema de salud en fallecer.</p>
02 de mayo de 2020	<p>El peor día hasta la fecha en Chile.</p> <p>Se registran casi 1500 nuevos infectados junto con 13 muertes en tan solo un día. Esta cifra fue confirmada por el Ministerio de Salud que declaró el brote más fuerte. Entre los muertos, hay otro funcionario de salud.</p>
05 de mayo de 2020	<p>Más de veinte mil casos activos en Chile.</p> <p>Tras el último reporte oficial lanzado por el Ministerio de Salud este martes, se confirman 1373 nuevos casos de COVID-19, de los cuales 56 son asintomáticos, y el país llega a 22,016 casos.</p>

Tabla 3.2: Cronología de la pandemia de COVID-19. Fuente: (C. Chile 2020).

3.3.2.-Metodología Estudio de Eventos

Para analizar el efecto del COVID-19 se realizó un estudio de eventos que incluyó datos de rendimientos diarios de la Bolsa de Comercio de Santiago, específicamente a las acciones listadas en el IPSA (Índice de Precios Selectivo de Acciones), donde los datos incluyeron activos agrupados por industria.

La metodología de estudio de eventos es ampliamente utilizada en finanzas para identificar los efectos de circunstancias o eventos en los mercados bursátiles, evaluando el nivel de eficiencia mediante el examen del ajuste de precios de los activos según informes de noticias que podrían afectar las empresas listadas en

la bolsa de valores. El objetivo de la metodología ayuda a observar si aparece una eficiencia anormal de las acciones como resultado en relación con los anuncios o eventos (Martín Ugedo 2003).

Las etapas del estudio de eventos son las siguientes:

- Determinación de la fecha del evento y períodos de estimación y anuncios

Al definir la frecuencia del estudio de eventos es un problema que se debe definir en forma correcta. Este estudio debe entregar la información necesaria para saber que tan rapido se incorpora la información en los precios. Esta frecuencia no se pueden establecer los retornos anuales, como tampoco retornos en 10 segundos, los investigadores suelen utilizar frecuencias diarias, semanales y mensuales. Se debe considerar la eficiencia en que se encuentra el mercado para definir las ventnas, si el mercado es eficiente en algunas de las forma de Fama & French, se deden definir horizontes cortos, los horizontes de pueden clasificar en cortos, cuando se utiliza un mes antes y un mes despues del evento, y un horizonte de largo plazo puede considerar hasta 5 años antes y después del evento.

Los periodos de estimación utilizados dentro de un estudio de eventos pueden variar y suelen oscilar entre 100 y 300 días para estudios de rentabilidad diarios y entre 24 y 60 meses para estudios de rentabilidad mensuales. En este caso, los períodos más largos mejoran la precisión en la estimación; sin embargo, períodos más cortos evitan errores dado que los parámetros no son estacionarios (Peterson 1989).

En la tabla 3.2, se pueden ver las ventanas en torno al evento que se han utilizado en mercados latinos americanos.

Estudio	Naturaleza del Evento	Días Evento
(Kräussl, 2005)	El impacto de 302 cambios en las tasas soberanas en la estabilidad financiera de 8 economías latinoamericanas.	-10 a +10
(Bin, Blenman, & Chen, 2004)	El efecto de valuación de 6 crisis monetarias en 21 ADR's mexicanos y 10 brasileños (en una muestra mundial de 73 ADR's)	-30 a +30

<i>(Castillo, 2004)</i>	172 anuncios de bonos chilenos (56) y ofertas de acciones (116)	-10 a +10
<i>(Morán, 2003)</i>	El efecto de adoptar una disposición opcional (contenida en un cambio regulatorio más amplio) en 17 acciones chilenas	-20 a +30
<i>(Tapia & Tokman, 2003)</i>	24 efectos cambiarios de la crisis del peso mexicano de 1994 en 15 ADRs chilenos	-3 a +3
<i>(Mathur, Gleason, Dibooglu, & Singh, 2002)</i>	El efecto contagio de la Crisis del Peso Mexicano de 1994 en 15 ADRs chilenos	-1 a 0
<i>(Bhattacharya, Daouk, Jorgenson, & Kehr, 2000)</i>	75 anuncios de noticias corporativas mexicanas	-80 a +10
<i>(Hensler, Herrera, & Lockwood, 2000)</i>	68 ofertas públicas iniciales (IPO) mexicanas	0 a +300
<i>(Maquieira & Osorio, 2000)</i>	129 anuncios de dividendos chilenos	-10 a +10
<i>(Parisi & Pérez, 2000)</i>	El impacto de los cambios de calificación de 88 bonos en los precios de las acciones chilenas	-10 a +15
<i>(Wilson, Saunders, & Caprio, 2000)</i>	El efecto de la Crisis del Peso Mexicano en seis índices del sector real y diez grupos financieros	-30 a +2
<i>(Saens, Rodrigo, 1999)</i>	19 anuncios de ADR-IPO chilenos	-10 a +10
<i>(Celis & Maturana, 1998)</i>	36 ofertas públicas iniciales chilenas	0 a +10


Tabla 3.2: Estudios de Eventos en Latinoamérica, Considerando las ventanas en torno al evento, fuente: (Saens & Sandoval, 2005)

Para el estudio de eventos con la llegada de pandemia de este capítulo, se fija la fecha del evento que se analizará, en este caso es. El día $t=0$ es el día 03 de marzo

de 2020, que corresponde al primer caso de COVID-19 en Chile. Los resultados se presentan para una ventana de [-10;+10] días en torno al primer caso de COVID-19 en Chile, se definen 10 días antes y diez días después, más el día del evento, comprende 21 días que equivale en promedio de los días hábiles de negociación en un mes de operaciones, no obstante, el análisis se realizó para un período de 424 días entre julio de 2019 a septiembre de 2020.

En la Figura 4, $t = 0$ es el período de anuncio, el período del evento va de $T_1 + 1$ a T_2 , el período de estimación anterior va de T_0 a T_1 y el período de estimación posterior al evento va de $T_2 + 1$ a T_3 .

Figura 3.4: Ventanas de estudio de eventos.



Los periodos de estudio antes y después del evento debieron establecerse de manera que contuvieran suficiente información para describir lo que está sucediendo en torno a la devolución de activos; por lo tanto, se seleccionó un rango de -10 días a +10 días desde T_0 (fecha del evento inicial), como se indicó anteriormente.

- Estimación de la rentabilidad extraordinaria

Para estimar la rentabilidad extraordinaria se utilizó la siguiente ecuación:

$$AR_{it} = R_{it} - E(R_{it}) \quad 3.2$$

$$E(R_{it}) = R_f + \beta(E(R_{mt}) - R_f) \quad 3.3$$

Donde AR_{it} = Es el retorno anormal i en tiempo t , R_{it} = rentabilidad real obtenida, $E(R_{it})$ = retorno esperado, R_f = Tasa libre de riesgo, β = riesgo sistemático, and $E(R_{mt})$ = retorno esperado de mercado.

El riesgo sistemático (beta) se calculó utilizando los rendimientos de cada sector industrial mediante estimación por mínimos cuadrados ordinarios. La estimación se realizó para los 157 días previos a la ventana previa al evento; luego se calculó el riesgo sistemático para los 10 días posteriores al evento.

- Obtener rendimientos anormales (AR)

Este tipo de análisis pretende obtener generalizaciones, evitando resultados aislados de una empresa en particular; por lo tanto, una vez estimadas las rentabilidades anormales (AR), se agregan de forma cruzada o agregadas por industria.

Calculado para cada fecha de evento para obtener el residual, este término se utiliza principalmente para diferenciar el rendimiento de la acción x en el día t del rendimiento esperado:

$$r_{it} = R_{it} - \hat{R}_{it} \quad 3.4$$

donde r_{it} representa la diferencia residual entre R_{it} , el retorno del activo i en tiempo t , y \hat{R}_{it} , el rendimiento proyectado o estimado.

Para cada día o mes dentro de un período de evento, se promedian los residuales entre acciones y títulos para obtener el residual promedio del período de estudio, y las acciones pueden agruparse por industria o varios sectores de acuerdo con los objetivos del análisis:

$$AR_t = \frac{\sum_{i=1}^n r_{it}}{N} \quad 3.5$$

donde AR_t es el promedio residual en el tiempo t , r_{it} son las acciones residuales en el momento t , y N es el número de acciones de la muestra.

Modelos utilizados para medir rendimientos anormales

Se han desarrollado varios modelos para revisar y cuantificar los rendimientos de los activos normales y determinar los rendimientos anormales. En este estudio, aplicamos tres de estos modelos ([Peterson 1989](#)).

3.3.3.-Modelo de rendimiento medio ajustado: MRPA (método A)

El modelo de rentabilidad media ajustada supone que la rentabilidad ex ante normal del activo i es equivalente a la rentabilidad media diaria de las acciones estimadas, que puede variar entre poblaciones. El rendimiento anormal, AR, es

el mismo después de deducir el rendimiento normal, R_t , del rendimiento actual observado.

$$AR_{it} = R_{it} - \bar{R}_i \quad 3.6$$

Donde AR_{it} es el retorno anormal, R_{it} es el retorno del activo i en el periodo t , y \bar{R}_i es el promedio simple del rendimiento de los activos en el período de estimación.

3.3.4.-Modelo de rendimiento de mercado ajustado: MRMA (método B)

Este es un modelo más simple que se basa en el modelo anterior, donde se supone que el rendimiento estimado del activo estudiado es igual al rendimiento del mercado; por lo tanto, el modelo expresa que $\hat{\alpha}_i = 0$ and $\hat{\beta}_i = 1$, dado que alfa es casi consistentemente una cifra menor y el promedio beta (riesgo sistemático) de todos los negocios es el siguiente:

$$AR_{it} = R_{it} - R_{mt} \quad 3.7$$

donde AR_{it} es el retorno anormal, R_{it} es el retorno del activo i en el período t , y R_{mt} es el rendimiento del índice de mercado en el día t .

3.3.5.-Modelo de mercado: MM (método C)

Este método considera todas las variables de mercado y el riesgo sistemático de cada activo. Este modelo de retorno de un factor fue desarrollado por Sharpe (Sharpe 1963) y se define en la siguiente ecuación:

$$R_{it} = \alpha_i + \beta_i R_{mt} + \varepsilon_{it} \quad 3.8$$

donde R_{it} es el retorno del activo i en el tiempo t , α_i representa los rendimientos no explicados por el modelo, β_i es el riesgo sistemático del activo i , R_{mt} es el rendimiento del mercado en el momento t , y ε_{it} es el error estadístico.

Se pronostica la rentabilidad de un negocio y se adquiere el período del evento a través del modelo de mercado:

$$E(R_{it}) = \hat{\alpha}_i + \hat{\beta}_i R_{mt} \quad 3.9$$

Este modelo se conoce como modelo índice. Existen otras variantes del modelo, que incluyen diferentes factores (MacKinlay 1997):

$$AR_{it} = R_{it} - E(R_{it}) \quad 3.10$$

Donde AR_{it} es el rendimiento anormal de las acciones i en el día t y $E(R_{it})$ es el rendimiento esperado obtenido utilizando el CAPM.

4. Obtener rentabilidades anormales acumuladas (CAR)

En esta etapa se acumulan todos los rendimientos anormales:

$$CAR = \sum_{t=-10}^{10} AR_t \quad 3.11$$

Donde CAR es el residual promedio acumulado y AR_t es el promedio residual en el tiempo t .

3.3.6.-Rendimientos anormales de compra y retención (BHAR)

En este paso, la rentabilidad anormal (AR) se calcula a partir de rentabilidades compuestas (rentabilidades anormales de comprar y mantener, o BHAR), donde las rentabilidades anormales a largo plazo se calculan a partir de las rentabilidades a corto plazo para obtener la rentabilidad en la ventana del evento, siguiendo la estrategia de comprar y mantener durante dicho período. Inicialmente, se estima el rendimiento en la ventana de eventos para el título i utilizando la siguiente expresión:

$$BHR_{i\tau} = \left[\prod_{t=s}^{s+\tau} (1 + R_{it}) \right] - 1 \quad 3.12$$

donde s es el mes del evento, R_{it} es el rendimiento del activo i en el momento t y τ es el horizonte temporal posterior al evento. A la rentabilidad del activo compuesto se le resta la rentabilidad anormal obtenida (BHAR) (BHR).

$$BHAR_{i\tau} = BHR_{i\tau} - BHR_{control,\tau} \quad 3.13$$

Como tenemos una muestra transversal promedio $BHAR_{i\tau}$, Para medir el comportamiento anormal de las empresas de la muestra se utiliza el siguiente estimador:

$$BHAR_{\tau} = \sum_{i=1}^N w_i * BHAR_{i\tau} \quad 3.14$$

donde N es el número de eventos en la muestra, w_i es el peso asignado a la empresa i, y τ es el horizonte de tiempo del cálculo después del evento.

3.3.7.-La significancia estadística contrasta con la rentabilidad extraordinaria

Una revisión de significancia estadística es útil ya que puede respaldar las conclusiones del estudio. Al utilizar este método, los resultados de la regresión residual se validan para cada período como con el residual acumulativo.

Las hipótesis contrapuestas son:

H_0 = no hay evidencia de retorno anormal existente; y

H_1 = evidencia de retorno anormal existente.

El valor t de Student se calcula utilizando la siguiente ecuación:

$$\frac{AR_t}{\hat{S}(AR)} = \frac{AR_t}{\left[\frac{1}{178} \sum_{t=-157}^{-21} (AR_t - AR)^2 \right]^{\frac{1}{2}}} \quad 3.15$$

donde $\hat{S}(AR)$ corresponde a la desviación estándar obtenida de los datos en una ventana libre de información relacionada con el evento. En este proceso, la significación estadística debe estimarse de la siguiente manera:

$$\frac{CAR}{\hat{S}(CAR)} = \frac{\sum_{t=-10}^{+10} AR_t}{\sum_{t=-10}^{+10} \hat{S}(AR)} \quad 3.16$$

Los rendimientos de las distintas acciones se distribuyen por igual y de forma independiente, ya que pueden incluir errores y pueden existir ciertos sesgos en la obtención de estimaciones.

3.3.8.-Análisis de Reacción a Nueva Información en el Mercado

Cuando ocurren noticias que pueden afectar los precios de los activos en el mercado de valores, estos precios pueden reaccionar de forma aleatoria; así lo estableció Kendall, cuyo estudio propone que no se puede establecer un patrón de precios de activos que permita predecir sus precios futuros porque los precios se comportan aleatoriamente en mercados que se comportan eficientemente; por lo tanto, los precios de las acciones se vuelven impredecibles ([Kendall y Bradford Hill 1953](#)).


Antes de que se incorpore nueva información al mercado, se pueden visualizar tres posibles reacciones:

En la Figura 3.5, se pueden observar las siguientes reacciones ante un evento que afecta el mercado de valores:

- 1) La incorporación de la nueva información en el tiempo $t = 0$ y la implementación de una corrección adecuada.
- 2) Una sobrerreacción positiva a las noticias, donde los precios reaccionan antes y se corrigen lentamente. También puede ser una sobrerreacción negativa en el caso de que la noticia afecte negativamente al precio del activo.
- 3) Una reacción retardada; el precio del activo no reacciona en $t = 0$ antes del comunicado de prensa, pero sí reacciona después de la noticia que afecta al mercado.

En los puntos 2 y 3, el mercado no reacciona de manera eficiente; por lo tanto, se infiere que los precios no se comportan aleatoriamente, como lo establece Kendall.

Figura 3.5: Explicación de la reacción del evento



3.4.-Resultados

Se utilizaron pruebas paramétricas y no paramétricas para determinar si estas evaluaciones son sólidas. Estas son medidas muy específicas y han funcionado en países fuera de los Estados Unidos (Campbell, Cowan y Salotti 2010). En nuestro caso, asumimos que la llegada del COVID-19 a Chile generó mayores rendimientos irregulares, tanto positivos como negativos, por lo que el estadístico t variará significativamente de 0.

En la Tabla 3.3, se presentan estadísticas descriptivas de retorno correspondientes a una muestra de diarios de retorno que se empleó para determinar las ventanas del estudio de eventos.

Industria	Promedio	Mediana	Varianza	Desv. Standard	Skewness	Curtosis
Banca	-0.26%	-0.12%	0.0005	0.02	-0.75 *	9.79 **
Commodities	-0.08%	-0.22%	0.0008	0.03	-1.48 *	10.46 **
Const. & Inmob.	-0.25%	-0.30%	0.0008	0.03	-0.46 *	9.00 **
Consumo	-0.13%	-0.10%	0.0003	0.02	-1.06 *	6.27 **
Holding	-0.25%	-0.05%	0.0005	0.02	-0.45 *	13.26 **
Industrial	-0.24%	-0.05%	0.0003	0.02	-3.69 *	33.39 **
Retail	-0.32%	-0.20%	0.0008	0.03	-1.23 *	13.73 **
IT	-0.28%	-0.26%	0.0008	0.03	-0.56 *	7.45 **
Comunicaciones	-0.14%	-0.07%	0.0010	0.03	-0.38 *	4.92 **
Trans. Aéreo	-0.70%	-0.16%	0.0066	0.08	-3.57 *	27.17 **

Utilities	-0.11%	-0.09%	0.0004	0.02	-1.41 *	13.80 **
-----------	--------	--------	--------	------	---------	----------

Tabla 3.3: Datos estadísticos de la serie de retorno utilizada en este estudio. . Software utilizado Rstudio.

* Si Skewness < 0, la distribución es asimétrica negativa o se alarga en el lado izquierdo. ** Si Curtosis > 3, corresponde a una distribución leptocúrtica.

En la tabla 3.3 se muestran los estadísticos básicos de la serie de datos utilizada, en la que se puede apreciar entre los estadígrafos la curtosis donde indica que es mayor a cero, obteniendo que la distribución corresponde a una distribución leptocúrtica.

En la Tabla 3.4 se muestra un total de 228 retornos diarios disponibles para las industrias dentro del IPSA. Las pruebas de normalidad utilizadas para los datos del período estimado incluyeron pruebas de normalidad de Shapiro-Wilk, Anderson-Darling, Lilliefors y Jarque-Bera, donde las hipótesis fueron las siguientes: Hipótesis 0, los rendimientos se distribuyen normalmente; Hipótesis 1, los rendimientos no se distribuyen normalmente.

Industria	Test de Normalidad					
	Kolmogorov-Smirnov **			Shapiro-Wilk		
	Statistical	gl	Sig.	Statistical	gl	Sig.
Banca	0.149	228.000	0.000 *	0.843	228.000	0.000 *
Commodities	0.086	228.000	0.000 *	0.876	228.000	0.000 *
Const. &Inmob.	0.122	228.000	0.000 *	0.866	228.000	0.000 *
Consumo	0.132	228.000	0.000 *	0.903	228.000	0.000 *
Holding	0.131	228.000	0.000 *	0.826	228.000	0.000 *
Industrial	0.165	228.000	0.000 *	0.717	228.000	0.000 *
Retail	0.143	228.000	0.000 *	0.808	228.000	0.000 *
IT	0.095	228.000	0.000 *	0.912	228.000	0.000 *
Comunicaciones	0.084	228.000	0.001 *	0.937	228.000	0.000 *
Trans. Aéreo	0.218	228.000	0.000 *	0.589	228.000	0.000 *
Utilities	0.145	228.000	0.000 *	0.811	228.000	0.000 *

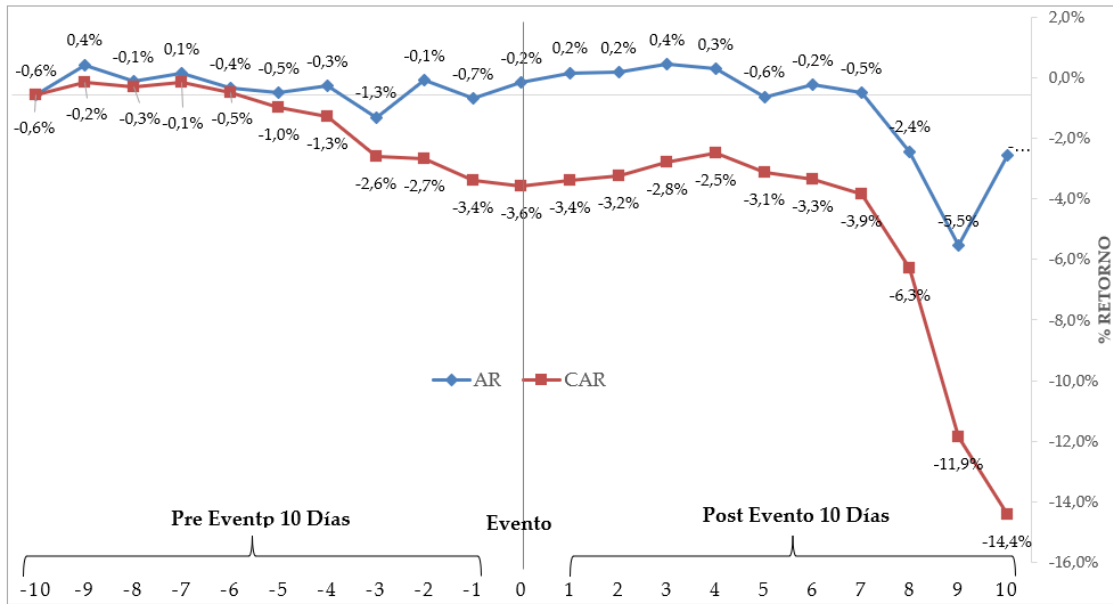
Tabla 3.4: significación estadística por industria de la prueba de normalidad. . Software utilizado Rstudio.

** Corrección de significación de Lilliefors. * Dado que el valor p calculado es menor que el nivel de significación alfa = 0,05, se debe rechazar la hipótesis nula H_0 , que corresponde a la distribución normal de los datos.

Para todas las industrias, el p-value fue diferente de 0 y para algunas pruebas fue prácticamente cero, lo que indica que la muestra para el estudio de eventos no se distribuye normalmente.

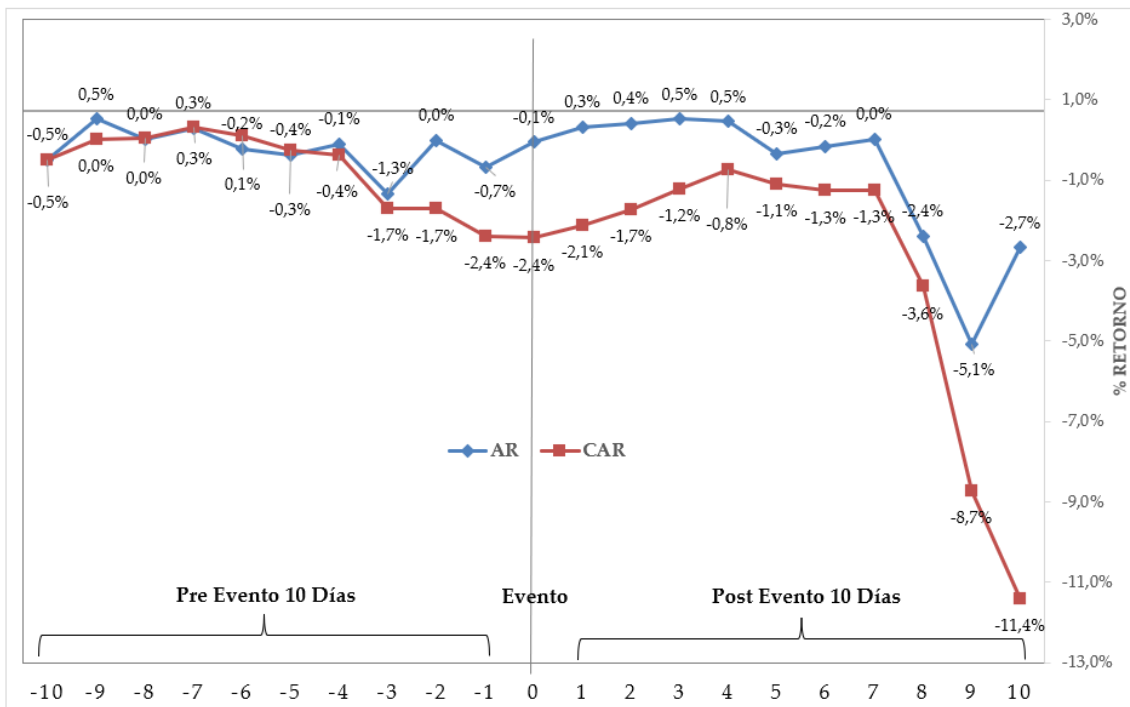
En la Figura 3.6, el día del evento, los rendimientos anormales de las industrias que conforman el IPSA aumentan luego de las caídas de los días -3 y -1, continúan aumentando hasta el día 3, y luego comienzan a disminuir a partir del día 4 hasta el día 10, mientras que los rendimientos anormales acumulados disminuyen continuamente hasta el día del evento, luego aumentan hasta el día 4 y finalmente continúan disminuyendo.

Figura 3.6: Rendimientos anormales y rendimientos anormales acumulados (método MRMA).




En la Figura 3.7, las rentabilidades anormales son negativas el día -10, positivas entre los días -9 y -7 (similares a las rentabilidades anormales acumuladas obtenidas), y luego permanecen negativas hasta el día del evento. Sin embargo, los rendimientos anormales del día 1 al día 4 son positivos y luego se vuelven negativos del día 5 al 10, mientras que los rendimientos anormales acumulados del día 4 siguen siendo negativos.

Figura 3.7: Rendimientos anormales y rendimientos anormales acumulados (método MRPA).



En la Figura 3.8, tanto los rendimientos anormales como los rendimientos anormales acumulados son negativos hasta el día -4. Las rentabilidades anormales siguen siendo positivas hasta el día del evento, pero solo vuelven a ser positivas los días 6 y 10. Sin embargo, las rentabilidades anormales acumuladas son siempre negativas.

Figura 3.8: Rendimientos anormales y rendimientos anormales acumulados (método MM).



Puesto que la muestra de datos no mostró una distribución normal, fue necesario utilizar pruebas no paramétricas para evaluar los retornos anormales. Por lo tanto, se presentan tablas que muestran los resultados de la aplicación de la prueba de rangos con signo de Wilcoxon.

Dado que los rendimientos no se distribuyen normalmente y tienen una forma más leptocúrtica (como se ve generalmente en las series financieras), se rompe la supuesta normalidad en los modelos de predicción de precios financieros, donde el riesgo de cola puede aparecer como producido en el mundo real. Los modelos establecidos con supuesta normalidad no pueden modelar movimientos de retorno fuera de la supuesta normalidad (Sin-Yi 2011). En este caso, el activo se muestra inclinado hacia la izquierda de la curva (inclinación negativa), donde se da un exceso de curtosis; el impacto se produce por la asignación de activos dentro de una cartera, especialmente en periodos de crisis, como se analizó en la crisis sub prime de 2008 (Xiong y Idzorek 2011). Por lo tanto, los modelos basados en una supuesta normalidad, como las evaluaciones de activos, pueden cometer el error de sobrevalorar o infravalorar los rendimientos.

La Tabla 3.5 muestra que las estadísticas de Wilcoxon para todos los días a lo largo de la ventana de estudio no tienen significación estadística; por lo tanto, no se puede rechazar la hipótesis nula. Así, la mediana poblacional es igual a cero para las rentabilidades anormales obtenidas por el método MRMA para las industrias analizadas en las ventanas pre y post evento y el día del evento, lo que indica que las diferencias en la muestra se deben a al azar.

Método	Día	Z	P-Value	Día	Z	P-Value
MRMA	Día -10	-1.29 *	0.20 **	Día 1	0.49 *	0.62 **
MRMA	Día -9	-0.04 *	0.96 **	Día 2	0.58 *	0.56 **
MRMA	Día -8	-0.40 *	0.69 **	Día 3	0.93 *	0.35 **
MRMA	Día -7	0.93 *	0.35 **	Día 4	1.29 *	0.20 **
MRMA	Día -6	-0.04 *	0.96 **	Día 5	0.13 *	0.89 **
MRMA	Día -5	-1.64 *	0.10 **	Día 6	-0.04 *	0.96 **
MRMA	Día -4	-0.22 *	0.82 **	Día 7	0.22 *	0.82 **
MRMA	Día -3	-1.56 *	0.12 **	Día 8	-1.73 *	0.08 **
MRMA	Día -2	0.22 *	0.82 **	Día 9	-1.56 *	0.12 **
MRMA	Día -1	-1.73 *	0.08 **	Día 10	-2.00 *	0.05 **
MRMA	Día 0	-0.49 *	0.62 **			

* El RANK Test acepta la hipótesis nula. ** P-Value > 0,05, valor no presenta significación estadística.

Tabla 3.5: Prueba de rangos con signo de Wilcoxon, método MRMA. . Software utilizado Rstudio.

La Tabla 3.6 muestra que la mayoría de las estadísticas de Wilcoxon no tienen significación estadística tanto en las ventanas previas y posteriores al evento como en el día del evento; por lo tanto, no se puede rechazar la hipótesis nula. La hipótesis nula solo se puede rechazar el día 10 posterior al evento. Sin embargo, en los días estudiados, la mediana poblacional es igual a cero entre las rentabilidades anormales obtenidas por el método MRPA de las industrias analizadas en las ventanas pre y post evento y en el día del evento, indicando que las diferencias en la muestra se deben al azar.

Método	Día	Z	P-Value	Día	Z	P-Value
MRPA	Día -10	-1.11 *	0.27 **	Día 1	0.67 *	0.50 **
MRPA	Día -9	0.49 *	0.62 **	Día 2	0.58 *	0.56 **
MRPA	Día -8	0.04 *	0.96 **	Día 3	1.29 *	0.20 **
MRPA	Día -7	1.02 *	0.31 **	Día 4	1.64 *	0.10 **
MRPA	Día -6	0.31 *	0.76 **	Día 5	0.84 *	0.40 **
MRPA	Día -5	-1.38 *	0.17 **	Día 6	0.04 *	0.96 **
MRPA	Día -4	-0.13 *	0.89 **	Día 7	1.38 *	0.17 **
MRPA	Día -3	-2.36 *	0.02 **	Día 8	-1.64 *	0.10 **
MRPA	Día -2	0.49 *	0.62 **	Día 9	-0.84 *	0.40 **
MRPA	Día -1	-1.82 *	0.07 **	Día 10	-2.00 *	0.05 **
MRPA	Día -0	0.04 *	0.96 **			

* El RANK Test acepta la hipótesis nula. ** P-Value > 0,05, valor no presenta significación estadística.

Tabla 3.6: Prueba de rangos con signo de Wilcoxon, método MRPA. . Software utilizado Rstudio.

La Tabla 3.7 muestra que la mayoría de los estadísticos de Wilcoxon tienen significación estadística, al contrario de los datos de los otros modelos, por lo que se rechaza la hipótesis nula, excepto en los días -10, -9, -2, 0, 6 y 8. No obstante, en los días estudiados, la mediana poblacional es diferente de cero entre los retornos anormales obtenidos por el método MM para las industrias analizadas en las ventanas pre y post evento y en el día del evento, lo que sugiere que las diferencias en la muestra no se deben al azar.

Método	Día	Z	P-Value	Día	Z	P-Value
MM	Día -10	-0.04 *	0.96 **	Día 1	-2.89	0.00
MM	Día -9	0.49 *	0.62 **	Día 2	-2.89	0.00
MM	Día -8	-2.89	0.00	Día 3	2.53	0.01
MM	Día -7	-2.18	0.03	Día 4	-2.71	0.01
MM	Día -6	-2.89	0.00	Día 5	-2.89	0.00
MM	Día -5	-2.71	0.01	Día 6	1.64 *	0.10 **
MM	Día -4	-2.89	0.00	Día 7	-2.89	0.00

MM	Día -3	2.80	0.01	Día 8	-1.02 *	0.31 **
MM	Día -2	0.67 *	0.50 **	Día 9	-2.89	0.00
MM	Día -1	2.36	0.02	Día 10	2.62	0.01
MM	Día 0	-2.80	0.01			

* El RANK Test acepta la hipótesis nula. ** P-Value > 0,05, valor no presenta significación estadística.

Tabla 3.7: Prueba de rangos con signo de Wilcoxon, método MRPA. . Software utilizado Rstudio.

En conclusión, los resultados de la prueba de rangos con signo indican que no existen diferencias significativas en los datos de rendimientos anormales de las industrias obtenidos por los modelos MRMA y MRPA en la ventana previa al evento, el día del evento y después del evento. Diferencias significativas en los retornos anormales solo se obtuvieron por el método MM. Esto sugiere que los retornos anormales se vieron afectados por las noticias de la pandemia en las ventanas antes y después del evento.

La Tabla 3.8 muestra los resultados de la prueba t pareada entre las ventanas pre y post evento por industria, empleada en desempeños logarítmicos de industrias listadas en el IPSA (Índice de Precios Selectivo de Acciones) a través del método de modelo de mercado (MM). Todas las industrias demostraron un desempeño promedio negativo antes y después de la llegada del COVID-19 a Chile, solo el sector bancario obtiene rendimientos positivos. De acuerdo con el modelo de rentabilidad ajustada al mercado (MRPA), el sector bancario presentó rentabilidades promedio positivas en las ventanas de 10 días antes y después del evento; los sectores holding y minorista presentaron retornos promedio positivos antes del evento; y el sector de tecnologías de la información, el sector de las comunicaciones y el sector de servicios públicos presentaron retornos promedio positivos, todos después del evento. En cuanto a los resultados obtenidos del modelo de rentabilidad ajustada al mercado (MRPA), el sector bancario obtuvo una rentabilidad promedio positiva en ambas ventanas; sin embargo, todos los demás sectores (comunicaciones, tecnología de la información, viajes aéreos, productos básicos, construcción y bienes raíces, holding y comercio minorista) mostraron rendimientos promedio negativos antes y después del evento.

Industria	Método MRPA				Método MRMA				Método MM			
	Mediana		t-Value	P-Value	Mediana		t-Value	P-Value	Mediana		t-Value	P-Value
	pre (10 días)	post (10 días)			pre (10 días)	post (10 días)			pre (10 días)	post (10 días)		
Banca	0.004	0.008	-1.00	0.22 **	0.002	0.005	-0.60	0.22 **	0.001	-0.024 *	1.31	0.22 **

Commodities	-0.004 *	-0.042 *	1.83	0.34 **	-0.004 *	-0.042 *	1.83	0.56 **	-0.004 *	-0.042 *	1.83	0.12 **
Const. & Inmob.	-0.002 *	0.000 *	-0.14	0.89 **	-0.005 *	-0.012 *	0.68	0.51 **	-0.005 *	-0.041 *	1.66	0.13 **
Consumo	-0.001 *	-0.002 *	0.29	0.78 **	-0.001 *	0.009	-1.31	0.22 **	-0.003 *	-0.021 *	1.44	0.18 **
Holding	0.001	-0.003 *	0.47	0.65 **	0.000	-0.008 *	0.88	0.40 **	-0.002 *	-0.038 *	2.15	0.06 **
Industrial	-0.005 *	-0.015 *	0.97	0.36 **	-0.004 *	0.000	-0.44	0.67 **	-0.006 *	-0.030 *	1.42	0.19 **
Retail	0.001	-0.013 *	1.33	0.22 **	-0.001 *	-0.021 *	1.85	0.10 **	-0.002 *	-0.050 *	2.07	0.07 **
IT	-0.001	0.002	1.83	0.64 **	-0.003 *	-0.004 *	1.83	0.90 **	-0.003 *	-0.032 *	1.35	0.21 **
Comunicaciones	-0.004	0.004	-0.71	0.50 **	-0.006 *	-0.007 *	0.04	0.97 **	-0.007 *	-0.036 *	1.90	0.09 **
Trans. Aéreo	-0.016	-0.086 *	1.47	0.18 **	-0.015 *	-0.082 *	1.46	0.18 **	-0.019 *	-0.114 *	1.53	0.16 **
Utilities	-0.004	0.009	-1.70	0.12 **	-0.003 *	0.011	-1.85	0.10 **	-0.006 *	-0.019 *	0.85	0.42 **

Tabla 3.8: Resultados de la Test t para las ventanas previas y posteriores al evento. . Software utilizado Rstudio.

* Rentabilidad media negativa. ** P-Valor > 0.05, la hipótesis nula aún no puede ser rechazada, por lo tanto, se afirma la hipótesis de que la población promedio es diferente.

Todos los resultados se obtuvieron mediante una prueba de dos colas. Los resultados de todas las industrias tienen una significación superior al 5% ($p > 0,05$); sin embargo, la hipótesis nula aún no puede ser rechazada.

De acuerdo con las Tablas 3.9 y 3.10, la industria menos afectada antes y después del evento fue el sector bancario, y la más afectada fue el transporte aéreo. El sector de servicios públicos no se vio afectado antes del evento, de acuerdo con todos los métodos, pero con el método MRPA se observaron rendimientos negativos anormales durante y después del evento. En menor medida, las industrias de consumo, TI, comunicación, industrial y retail enfrentaron un bajo impacto tras el brote del virus en Chile; sin embargo, de acuerdo con los valores de p en la ventana posterior al evento, se volvieron estadísticamente significativos. Este estudio se alinea con los resultados del informe de política monetaria (IPOM) de marzo de 2020 realizado por el Banco Central de Chile para nivelar los precios del IPSA, donde los mercados financieros locales respondieron con fuerza ante el cambiante escenario global. Como se observa en países comparables, estas variables han decaído en formas que no ocurrían desde el crack financiero de 2008. Desde mediados de febrero, el IPSA ha descendido hasta un 32%, registrando su peor sesión en más de 30 años (-14,3 %, 19 de marzo). Los sectores de comercio minorista, construcción y viajes aéreos fueron los más afectados financieramente (B. C. Chile 2020).

Table 9. Resultados del CAR que muestran el promedio de los retornos antes, durante y después del evento y su significación estadística.

Industria	Banca			Commodities			Const. & Inmob.		
Método	MRPA	MRMA	MM	MRPA	MRMA	MM	MRPA	MRMA	MM
Return (CAR)									
Evento	-0.8%	-0.1%	0.1%	-1.9%	-0.9%	-0.7%	-1.4%	-0.7%	-0.2%
Pre-Evento	0.7%	1.8%	3.5%	-3.6%	-0.8%	-0.2%	-5.3%	-4.6%	-1.8%
Post Evento	-24.4%	4.7%	8.5%	-41.7%	-10.9%	-2.7%	-40.6%	-11.8%	-0.2%
Total	-24.5%	6.4%	12.1%	-47.2%	-12.6%	-3.6%	-47.3%	-17.1%	-2.3%
<i>p</i> -value (CAR)									
Evento	0.59	0.90	0.85	0.35	0.40	0.51	0.51	0.61	0.87
Pre-Evento	0.88	0.43	0.11	0.57	0.82	0.94	0.44	0.28	0.65
Post Evento	0.00 *	0.03 *	0.00 *	0.00 *	0.00 *	0.43	0.00 *	0.01 *	0.96
Total	0.00 *	0.05 *	0.00 *	0.00 *	0.02 *	0.46	0.00 *	0.01 *	0.70
Industria	Consumo			 Holding			 Industrial		
Método	MRPA	MRMA	MM	MRPA	MRMA	MM	MRPA	MRMA	MM
Return (CAR)									
Evento	-0.6%	0.3%	0.0%	-2.4%	-1.6%	-1.4%	-0.2%	0.6%	0.2%
Pre-Evento	-2.6%	-0.5%	-1.0%	-1.6%	-0.3%	1.4%	-6.0%	-4.1%	-4.7%
Post Evento	-21.3%	8.9%	-2.4%	-37.7%	-8.3%	-3.4%	-29.9%	0.1%	-14.8%
Total	-24.5%	8.6%	-3.3%	-41.7%	-10.3%	-3.4%	-36.1%	-3.4%	-19.3%
<i>p</i> -value (CAR)									
Evento	0.61	0.74	1.00	0.19	0.15	0.21	0.79	0.53	0.76
Pre-Evento	0.45	0.85	0.67	0.79	0.93	0.70	0.04 *	0.17	0.03 *
Post Evento	0.00 *	0.00 *	0.31	0.00 *	0.02 *	0.34	0.00 *	0.97	0.00 *
Total	0.00 *	0.03 *	0.32	0.00 *	0.05 *	0.51	0.00 *	0.43	0.00 *
Industria	Retail			IT			Comunicaciones		
Método	MRPA	MRMA	MM	MRPA	MRMA	MM	MRPA	MRMA	MM
Return (CAR)									
Evento	-0.8%	-0.1%	0.3%	-0.6%	0.1%	0.4%	-0.3%	0.5%	0.9%
Pre-Evento	-2.1%	-1.2%	1.0%	-3.5%	-3.0%	-0.5%	-7.4%	-6.3%	-4.1%
Post Evento	-50.0%	-21.0%	-12.7%	-32.4%	-3.8%	2.4%	-35.8%	-6.6%	3.8%
Total	-53.0%	-22.3%	-11.5%	-36.5%	-6.8%	2.3%	-43.6%	-12.5%	0.6%
<i>p</i> -value (CAR)									
Evento	0.65	0.91	0.78	0.77	0.95	0.76	0.90	0.80	0.61
Pre-Evento	0.71	0.68	0.72	0.59	0.50	0.90	0.33	0.25	0.45
Post Evento	0.00 *	0.00 *	0.00 *	0.00 *	0.39	0.59	0.00 *	0.23	0.49
Total	0.00 *	0.00 *	0.01 *	0.00 *	0.30	0.72	0.00 *	0.12	0.94
Industria	Transporte Aéreo			Utilities					
Método	MRPA	MRMA	MM	MRPA	MRMA	MM			
Return (CAR)									
Evento	-2.0%	-1.0%	-1.2%	0.2%	1.1%	1.0%			
Pre-Evento	-18.6%	-14.9%	-16.3%	-5.9%	-3.3%	-3.5%			
Post Evento	-113.7%	-81.9%	-86.2%	-19.3%	11.4%	9.1%			

Total	-134.3%	-97.8%	-103.6%	-25.0%	9.2%	6.6%
<i>p</i> -value (CAR)						
Evento	0.49	0.71	0.65	0.89	0.08	0.09
Pre-Evento	0.04 *	0.07	0.05	0.17	0.09	0.07
Post Evento	0.00 *	0.00 *	0.00 *	0.00 *	0.00 *	0.00 *
Total	0.00 *	0.00 *	0.00 *	0.00 *	0.00 *	0.02 *

* *P*-Value < 0.05, significa que el valor es 95% estadísticamente significativo.

Tabla 3.9: Resultados del CAR que muestran el promedio de los retornos antes, durante y después del evento y su significación estadística.

Industria	Banca			Commodities			Const. & Inmob.		
Método	MRPA	MRMA	MM	MRPA	MRMA	MM	MRPA	MRMA	MM
Return (BHAR)									
Evento	-0.8%	-0.1%	0.1%	-1.9%	-0.9%	-0.7%	-1.4%	-0.7%	-0.2%
Pre-Evento	0.4%	1.7%	3.5%	-3.8%	-0.8%	-0.3%	-5.3%	-4.6%	-2.0%
Post Evento	-23.5%	4.8%	8.7%	-36.6%	-10.5%	-2.7%	-35.1%	-11.8%	-1.3%
Total	-23.8%	6.5%	12.7%	-40.2%	-12.0%	-3.7%	-39.5%	-16.4%	-3.4%
<i>p</i> -value (BHAR)									
Evento	0.59	0.90	0.85	0.35	0.40	0.51	0.51	0.61	0.87
Pre-Evento	0.93	0.43	0.11	0.54	0.82	0.94	0.43	0.28	0.62
Post Evento	0.00 *	0.03 *	0.00 *	0.00 *	0.00 *	0.42	0.00 *	0.01 *	0.75
Total	0.00 *	0.04 *	0.00 *	0.00 *	0.02 *	0.45	0.00 *	0.01 *	0.55
Industria	Consumo			Holding			Industrial		
Método	MRPA	MRMA	MM	MRPA	MRMA	MM	MRPA	MRMA	MM
Return (BHAR)									
Evento	-0.6%	0.3%	0.0%	-2.4%	-1.6%	-1.4%	-0.2%	0.6%	0.2%
Pre-Evento	-2.6%	-0.6%	-1.0%	-1.7%	-0.4%	1.2%	-5.9%	-4.1%	-4.6%
Post Evento	-20.1%	8.9%	-2.4%	-32.9%	-8.3%	-3.7%	-27.3%	-0.4%	-14.3%
Total	-22.6%	8.6%	-3.4%	-35.6%	-10.2%	-3.9%	-31.7%	-3.9%	-18.1%
<i>p</i> -value (BHAR)									
Evento	0.61	0.74	1.00	0.19	0.15	0.21	0.79	0.53	0.76
Pre-Evento	0.44	0.84	0.66	0.77	0.90	0.73	0.05 *	0.17	0.03 *
Post Evento	0.00 *	0.00 *	0.30	0.00 *	0.02 *	0.30	0.00 *	0.90	0.00 *
Total	0.00 *	0.03 *	0.31	0.00 *	0.05	0.45	0.00 *	0.36	0.00 *
Industria	Retail			IT			Comunicaciones		
Método	MRPA	MRMA	MM	MRPA	MRMA	MM	MRPA	MRMA	MM
Return (BHAR)									
Evento	-0.8%	-0.1%	0.3%	-0.6%	0.1%	0.4%	-0.3%	0.5%	0.9%
Pre-Evento	-2.3%	-1.3%	1.0%	-3.5%	-3.1%	-0.7%	-7.7%	-6.3%	-4.2%
Post Evento	-41.7%	-19.5%	-12.5%	-29.7%	-4.2%	1.9%	-31.9%	-6.7%	3.3%
Total	-43.5%	-20.6%	-11.4%	-32.5%	-7.1%	1.6%	-37.3%	-12.2%	-0.2%
<i>p</i> -value (BHAR)									
Evento	0.65	0.91	0.78	0.77	0.95	0.76	0.90	0.80	0.61
Pre-Evento	0.69	0.68	0.73	0.59	0.48	0.87	0.31	0.25	0.44
Post Evento	0.00 *	0.00 *	0.00 *	0.00 *	0.35	0.66	0.00 *	0.23	0.54


Total	0.00 *	0.00 *	0.01 *	0.00 *	0.28	0.80	0.00 *	0.13	0.98
Industria	Transporte Aéreo			Utilities					
Método	MRPA	MRMA	MM	MRPA	MRMA	MM			
Return (BHAR)									
Evento	-2.0%	-1.0%	-1.2%	0.2%	1.1%	1.0%			
Pre-Evento	-17.6%	-14.1%	-15.3%	-5.9%	-3.3%	-3.5%			
Post Evento	-78.3%	-63.5%	-65.6%	-19.1%	11.9%	9.3%			
Total	-82.4%	-68.9%	-71.2%	-23.7%	9.4%	6.6%			
p-value (BHAR)									
Evento	0.49	0.71	0.65	0.89	0.08	0.09			
Pre-Evento	0.05	0.09	0.07	0.17	0.09	0.07			
Post Evento	0.00 *	0.00 *	0.00 *	0.00 *	0.00 *	0.00 *			
Total	0.00 *	0.00 *	0.00 *	0.00 *	0.00 *	0.02 *			

* P-Value < 0.05, significa que el valor es 95% estadísticamente significativo.

Tabla 3.10: Resultados de BHAR que muestran el promedio de los retornos antes, durante y después del evento con su significancia estadística.

La figura 3.9, muestra el análisis de las rentabilidades anormales acumuladas. Se observa que, luego del primer caso confirmado de virus en Chile, los retornos fueron en su mayoría negativos. Por otro lado, los rendimientos anormales acumulados después del evento mostraron significación estadística. Aquí, los sectores financieros y de servicios públicos estuvieron menos expuestos a un colapso de la rentabilidad. Esta información es útil para el desarrollo de estrategias de inversión durante una emergencia sanitaria, considerando el riesgo sistemático a nivel mundial.

Figura 3.9: Rendimientos anormales acumulados por industrias (promedio de los tres métodos).



3.5.-Discusión

Las siguientes investigaciones fueron revisadas con el fin de justificar la aplicación de pruebas no paramétricas para la significancia estadística del estudio de eventos.

Un estudio verificó la metodología de los estudios de eventos con rendimientos diarios, evaluando problemas potenciales, como datos no regulares, sesgo de estimación en los parámetros de regresión utilizando un modelo de mercado y varianza de estimación, donde un aumento en la varianza indica un exceso de rendimiento medio dentro de los días, después del evento (Brown y Warner 1985).

Para el estudio de eventos es mejor utilizar pruebas no paramétricas que paramétricas, ya que estas últimas asumen la normalidad de los datos, mientras que las pruebas no paramétricas no suponen ningún tipo de distribución de datos.

Por tanto, para ver la robustez de un estudio, dado que las series de rendimientos financieros en general no se distribuyen normalmente, es preferible someter los datos a pruebas no paramétricas para estudios de eventos con rendimientos diarios (C. J. Corrado 1989); (Corrado y Zivney 1992).

Un estudio con acciones de Nasdaq reveló una irregularidad en los mercados desarrollados con la aplicación de pruebas estadísticas paramétricas sobre rendimientos anormales en un estudio de eventos. Esto refuerza que la prueba de rango (prueba no paramétrica) muestra la mayor consistencia durante el estudio de eventos para la determinación del desempeño anormal y su significancia estadística (Campbell y Wasley 1992).

En nuestro estudio, las pruebas no paramétricas fueron útiles porque después de revisar los datos, encontramos que no se distribuyeron normalmente en el período analizado; por lo tanto, estas pruebas mostraron que los datos son robustos desde un punto de vista estadístico.

Se han realizado diversos estudios para verificar la eficiencia del mercado de valores chileno. Siguiendo la técnica de Eugene Fama, se intentó averiguar si los precios de los activos financieros de los países miembros del MILA (Mercado

Integrado Latinoamericano) reflejaban toda la información histórica relevante. Se encontró que, con base en los resultados de la prueba de Dickey-Fuller, los mercados accionarios de Chile, Colombia, México y Perú tienen una eficiencia débil (Ramírez, Valencia y Villalba 2017).

Otros investigadores han tratado de comprobar la débil eficiencia de las cinco principales bolsas de valores de América Latina. Utilizaron dos técnicas: primero, probaron la normalidad de la serie, donde los datos se evaluaron utilizando estadísticas básicas; luego se realizó una revisión de caminata aleatoria bajo diferentes métodos. El hallazgo obtenido fue que los mercados han experimentado un cambio de ineficiencia a eficiencia débil en el siguiente orden cronológico: México (2007), Brasil (2008), Colombia (2008), Chile (2011) y Perú (2012) (Duarte y Mascareñas 2014).

Un estudio realizado con 49 índices bursátiles de diferentes países utilizando la metodología de estudio de eventos detectó fuertes reacciones negativas de todos los índices bursátiles estudiados después del brote del virus, con los mercados asiáticos afectados más negativamente por la entrada de la pandemia en comparación con el mercado de los Estados Unidos; el impacto no fue tan significativo en las ventanas corta y larga del estudio (Pandey y Kumari 2020).

Otro estudio de eventos se llevó a cabo en el mercado de valores de Bangladesh, obteniendo rendimientos anormales (AR) y rendimientos anormales acumulados (CAR) a través de tres métodos: rendimiento promedio constante, modelo de rendimiento de mercado y modelo de mercado. Aquí, el primer caso de COVID-19 causó un efecto negativo en el mercado de valores, y estos resultados están respaldados con pruebas estadísticas, paramétricas y no paramétricas (Adnan, Hasan y Ahmed 2020).

En los mercados latinoamericanos, los estudios han mostrado una caída vertiginosa de los índices compuestos en el MILA (Mercado Integrado Latinoamericano) alrededor de marzo, justo cuando la región enfrentaba la llegada de la pandemia. El análisis se realizó con cinco meses de rendimientos considerando índices de varios mercados, entre ellos el IPSA (Doria y Nuñez 2020).

Otros efectos del COVID-19 en los principales mercados bursátiles del mundo han analizado dónde los individuos podrían beneficiarse de un mercado afectado por la pandemia. Desde esta perspectiva, los mercados reaccionarán negativamente en el corto plazo, por lo que es posible invertir en empresas cuyos precios han bajado significativamente; estos precios bajos se corregirán a largo plazo. Se ha llevado a cabo un análisis por industria, centrándose en los sectores de viajes, tecnología, entretenimiento y productos básicos (oro), áreas donde eventualmente se pueden obtener grandes ganancias (Yan, y otros 2020).

Otro estudio del comportamiento de los índices bursátiles de Australia, Austria, Bélgica, Canadá, Dinamarca, Finlandia, Francia, Alemania, Reino Unido, España, Irlanda, Israel, Italia, Países Bajos, Nueva Zelanda, Noruega, Portugal, Singapur, Suecia, Suiza, Japón y Estados Unidos encontraron que las bolsas de valores no siempre incorporan toda la información disponible; en muchos casos, actúan con lentitud a la hora de evaluar las noticias. Mediante un simple análisis estadístico, se demostró que la respuesta de los mercados a la información disponible fue irracional e ineficaz. El brote de COVID-19 se da como ejemplo de una subestimación del riesgo para la salud y una respuesta inesperadamente lenta durante el evento; los autores sugieren que este fenómeno debería examinarse en el futuro desde una perspectiva conductual y que brinda la oportunidad de buscar las correcciones necesarias de los modelos de valoración de activos para este nuevo escenario mundial (Vasileiou, y otros 2021).

Un estudio sobre el mercado de capitales de Estados Unidos mostró que el mercado fue ineficiente durante las semanas posteriores al inicio de la pandemia de COVID-19. Esta ineficiencia significaba que los agentes podían maximizar sus ganancias desde febrero hasta finales de marzo de 2020, y podían generar ganancias extraordinarias utilizando únicamente precios históricos y datos relacionados con el virus para pronosticar los rendimientos futuros de ETF de acciones (Navratil, Taylor y Vecer 2021). Según investigaciones realizadas con la metodología de estudio de eventos sobre la eficiencia de los mercados de economías emergentes denominados BRIC (Brasil, Rusia, India y China), todos estos mercados acumularon retornos anormales negativos, con excepción de China. De los cuatro países, solo China tuvo una mejor respuesta entre el anuncio del H1N1 y el COVID-19, posiblemente por la capacidad de transformación de sus empresas ante la emergencia del H1N1, cumpliendo así con la hipótesis de mercados EMH eficientes como reducción de la ansiedad, provocando una

reacción más efectiva de los mercados bursátiles y proporcionando una eficiencia semifuerte (Sepúlveda, Tapia y Pastén 2021).

Además, en un estudio sobre la reacción de las bolsas de valores de los países del G20 ante el brote de COVID-19, se detectó una reacción negativa ante el brote del virus; sin embargo, los retornos anormales acumulados se fueron tornando positivos. La conclusión y recomendación respecto a la sobrerreacción de los mercados es que los inversores deben tener estrategias de inversión a largo plazo ante rebrotes, comprando acciones a corto plazo, con rendimientos afectados negativamente por la llegada de la pandemia (Singh, y otros 2020).

Otro estudio que involucró a la Bolsa de Valores de Dhaka de Bangladesh revisó la hipótesis de la aleatoriedad en los rendimientos de las acciones frente a la pandemia. Se encontró que la Bolsa de Valores de Dhaka no mostró ni siquiera una eficiencia débil en el período analizado (Ahmed 2021). Mientras tanto, un estudio de varios índices de varios mercados bursátiles sugirió que los mercados estudiados reaccionaron de forma exagerada con los precios (reacción exagerada), y a medida que hubo más información disponible, esto se corrigió (Phan y Narayan 2020).

En cuanto al índice SP&500 en el mercado financiero de Estados Unidos, se encontró que este mercado desarrollado no siempre fue eficiente ante el brote de COVID-19 (Evangelos 2020).

Otro estudio sobre el efecto de las emergencias sanitarias en el valor de las acciones en la región asiática considerando el brote de SARS encontró una ventana a corto plazo en la que China y Vietnam se vieron afectados, mientras que los mercados bursátiles de otros países no sufrieron impactos negativos (Nippani y Washer 2004).

Adicionalmente, otros estudios se han enfocado en ciertas industrias, específicamente la industria de la hospitalidad, la cual, en teoría, enfrentó un mayor impacto debido a las regulaciones sanitarias y los cierres de fronteras. Un estudio de esta naturaleza se llevó a cabo en Taiwán luego del brote del virus SARS y mostró un impacto en los retornos compartidos para la industria hotelera del país (Chen, Jang y Kim 2007).

Al igual que otros mercados, la bolsa chilena ha mostrado grandes pérdidas con la emergencia sanitaria mundial, como se puede apreciar en los resultados; solo el sector de los servicios públicos se vio menos afectado. Con este estado del mercado, como se indica en estudios anteriores, es útil aplicar una estrategia de inversión a largo plazo, ya que se espera que las caídas de precios de los activos se corrijan a largo plazo. Al igual que en estudios anteriores, el mercado chileno también está mostrando una lenta incorporación de información en el precio de los activos.

3.6.-Conclusión del capítulo

Desde el día que se anunció el primer caso de COVID-19 en Chile, la mayoría de las empresas listadas en el IPSA han tenido rentabilidades anormales acumuladas negativas según todos los métodos aplicados, excepto el sector de servicios públicos y en menor medida los sectores de consumo, industrial, TI y comunicaciones, que obtiene rentabilidades anormales acumuladas positivas.

Los resultados no fueron estadísticamente significativos en la ventana posterior al evento. El IPSA reaccionó de manera ineficiente ante el brote de COVID-19, mostrando una forma de eficiencia débil frente a una fecha de evento establecida. Además, se puede encontrar una reacción exagerada en la caída de los retornos posterior al evento dentro de todas las empresas que cotizan en IPSA, lo que destaca la ineficiencia del mercado chileno en la emergencia sanitaria. Como también lo comprueba en otro mercado y otra crisis un estudio que emplea la hipótesis de sobrerreacción a la crisis financiera global, en el mercado bursátil de China, en un período de 2009 y 2014 (Reddy, Ali Jibran Qamar, Mirza, & Shi, 2020). Otra investigación aplicada a mercados emergentes latinoamericanos, entre ellos Chile, México y Perú, utilizando un período que comprenda la crisis Subprime. Obtiene como hallazgo una sobrerreacción de los mercados, sugiriendo la utilización de información que dé cuenta del comportamiento de los agentes en los mercados (finanzas conductuales), por el efecto de la aversión a las pérdidas. (Agosin & Huaita, 2012). En este mismo sentido un estudio aplicado al mercado de valores de Pakistán, con datos de 2004 y 2015, obtiene como hallazgo una sobrerreacción del mercado en período de crisis, recomendando incorporar elementos de las finanzas conductuales, para estudios futuros. (Said, Ur Rehman, Ullah, & Khan, 2021). Como también hay estudios que revelan que los países emergentes sobre reaccionan a las crisis en mayor medida

que los países desarrollados. (Ramona, Razvan, & Costel, 2012). Otro estudio con países emergentes, encuentran que el mercado de valores de Santiago de Chile sobrerreaccionó a la crisis financiera global (Subprime), con posterior reversión de las pérdidas a largo plazo. (Abinzano, Muga, & Santamaria, 2010).

En resumen, los hallazgos de este estudio son los siguientes:

En primer lugar, el anuncio del primer caso confirmado en Chile generó retornos anormales acumulados negativos, excepto en los sectores industrial, commodities y comunicaciones, pero sin significación estadística. En la ventana pre-evento, todas las industrias, excepto la banca, obtuvieron rentabilidades anormales acumuladas negativas, también sin significación estadística, y en la ventana post-evento, todos los sectores excepto el de servicios públicos obtuvieron rentabilidades anormales acumuladas negativas, presentando significación estadística. Por lo tanto, esto sugiere la existencia de una reacción exagerada ante el primer caso de COVID-19 en Chile, excluyendo al sector de commodities. Ya en la década de los ochenta investigadores probaron que en los mercados desarrollados (CRSP Index), las personas tienden a "reaccionar de forma exagerada" ante eventos noticiosos inesperados y dramáticos (De Bondt & Thaler, 1985), otro estudio que analiza la sobrerreacción del mercado de valores en México, el cual utilizó un estudio de eventos de igual forma que este capítulo, aplicado en el período de la crisis subprime (2008-2009), concluye que el mercado de valores de México sobrerreaccionó frente a esta crisis, evidenciando una eficiencia débil del mercado (González Maiz Jiménez & Ortiz Calisto, 2020)

En segundo lugar, el sector de servicios públicos se vio menos afectado por el primer caso de coronavirus en Chile.

En tercer lugar, en el análisis de la ventana posterior al evento, las industrias no bancarias obtuvieron rendimientos anormales acumulados negativos superiores al -10% con significancia estadística, excepto el sector de servicios públicos, que obtuvo rendimientos anormales acumulados positivos.

En cuarto lugar, el estudio sugiere que el mercado no recopiló toda la información pública disponible sobre el primer caso de COVID-19 en Chile, y en todos los sectores excepto en el de utilities (servicios públicos) se observó una sobrerreacción tras el evento analizado.

Finalmente, al revisar el estudio de eventos, las industrias que conforman el IPSA reaccionaron lentamente a la información de la pandemia, y se obtuvieron rendimientos anormales por los tres métodos utilizados distintos a cero, lo que sugiere la existencia de ineficiencia de mercado en la incorporación de las noticias de la pandemia.

Con base en esta contingencia y el estudio del IPSA por industria, se puede sugerir a los analistas de inversiones que es posible adoptar una estrategia de inversión de largo plazo, excepto en el sector de servicios públicos, y es recomendable comprar acciones y obtener beneficios extraordinarios una vez superada la emergencia sanitaria o corregidas las rentabilidades anormales del mercado. Por otro lado, el sector de servicios públicos no presentó grandes pérdidas antes, durante y después del brote de COVID-19; por lo tanto, se convierte en un refugio para este mercado.

Finalmente respondiendo a la interrogante de que nivel de eficiencia financiera actuó el mercado chileno con la llegada del COVID-19, con fecha 03 de marzo de 2020, se aprecia que en los tres métodos estudiados, se espera que el mercado registre el impacto en los retornos, en este caso la caída de los retornos, en el caso de Chile no se aprecia la caída en los retornos anormales acumulados en el evento, tampoco en la ventana previa a este hecho, el mercado en los tres métodos comienza a caer en el día 7, lo que indica que no se comporta con ninguna forma de eficiencia financiera, además el mercado sobrerreaccionó posterior al evento, no tomando como en cuenta las noticias tanto locales como internacionales acerca de la pandemia.

En futuras investigaciones será útil realizar un estudio de causalidad de Granger entre la variable de nuevos casos de COVID-19 y el índice bursátil para encontrar un mejor modelo de valoración ante este nuevo escenario y este tipo de mercado. En ese sentido es interesante aplicar un estudio de eventos que tenga en cuenta la heteroscedasticidad (Modelo GARCH) y ampliar el mercado a los índices incluidos en el MILA (Mercado Integrado Latinoamericano), que considera cuatro países latinos: Chile, Colombia, México y Perú.

Capítulo 4 :Desempeño de modelos de valoración derivados del modelo CAPM, en periodo antes de pandemia y en crisis sanitaria, en el mercado bursátil chileno.

4.1.-Resumen del capítulo

En cuanto a la aplicación del modelo de valoración CAPM no está todo dicho, ya que su rendimiento varía de acuerdo con el mercado, período de estudio, nivel de incertidumbre y limitaciones. Por consiguiente, es de importancia la revisión de sus factores de riesgo, para determinar cuál de ellos aporta a explicar los rendimientos de los activos en un mercado en particular.

En este sentido la motivación de este trabajo es someter a revisión cuatro modelos de valoración de activos basados en el modelo CAPM, como lo es el original Capital Asset Pricing Model (CAPM), Fama French de tres factores (FF3M), Fama Cahart de cuatro factores (FC4F) y Fama French de cinco factores (FF5M), en el mercado bursátil chileno, entre el periodo de enero de 2007 y octubre de 2021, para responder la siguiente pregunta: ¿qué modelo captura mejor rendimiento en la predicción de los retornos de los activos que componen el índice IPSA de la bolsa de valores de Santiago de Chile?.

Este estudio se aplicará en dos partes, en el período completo y en período sin pandemia del COVID-19.

Para realizar el análisis se formarán portafolios ordenados, de forma dependientes e independientes, con el objetivo de obtener significancia estadística de los factores de riesgo de cada modelo, además de aplicar la prueba GRS, para revisar cuál es el modelo de mejor desempeño.

La respuesta a la pregunta de ¿qué modelo captura mejor rendimiento en la predicción de los retornos de los activos que componen el índice IPSA de la bolsa de valores de Santiago de Chile?, es la siguiente: para el periodo completo sometido a estudio, el modelo de mejor desempeño es modelo de Cahart de cuatro factores, sin embargo, en periodos sin pandemia también obtiene un mejor desempeño es el modelo de Fama French de cinco factores.

Es relevante destacar que en la crisis sanitaria los factores de riesgo de inversión y de rentabilidad operacional no tienen incidencia en el desempeño del modelo en la determinación del valor de los activos.

4.2.-Introducción

La importancia de identificar el mejor modelo de valoración de activos, en un mercado en particular, para explicar la variación transversal de los rendimientos de los activos es fundamental hacia el aseguramiento de un adecuado pronóstico de los precios de las acciones. Este proceso se logra sometiendo a prueba los modelos en un mercado en particular, sobre todo las adaptaciones de los nuevos factores de riesgo al modelo original CAPM desde 1993, realizados principalmente por los investigadores Fama y French ([Fama, Eugene; French, Kenneth, 1993](#)) ([Fama & French, 2015](#)). En ese sentido también otros investigadores modifican el modelo CAPM, como lo es la modificación al modelo de Fama propuesto por Carhart ([Carhart 1997](#)). La discusión de si estos factores de riesgo están relacionados con el riesgo fundamental es crítico y esencial en la valoración de los activos.

Los factores de riesgo de tamaño, valor, rentabilidad operacional, inversión y momentum, resultan ser mejor predictor del exceso de retorno de mercado en las investigaciones iniciales, pero no es concluyente, ya que existen mercados que reaccionan en un periodo de tiempo, mejor a otros factores, como lo son los indicadores macroeconómicos. Es así como el factor de inflación entre 1963 y 2017 en portafolios con activos de SP&500, resulta ser mejor factor riesgo en investigaciones recientes ([Leite, y otros 2020](#)).

El modelo CAPM (Capital Asset Price Model) de Sharpe y Lintner ([Lintner, 1965](#)) ([Sharpe 1964](#)) contiene un factor que es el exceso de rendimiento de mercado (RM-RF) o premio por riesgo, que se calcula por medio de los rendimientos de los activos menos el rendimiento del activo libre de riesgo.

La segunda propuesta de corrección al modelo incluye dos factores adicionales que son el tamaño de empresas (SMB), donde representa los retornos de las empresas pequeñas (SMALL) menos las empresas grandes (BIG). El factor tamaño fue confirmado en trabajos posteriores realizados con datos del índice NYSE, donde se construyeron treinta y tres portafolios ordenados por tamaño, que dan cuenta de que el factor de exceso de rendimiento de mercado no captura este efecto, bajo la idea que las empresas de menor capitalización bursátil tienen mayores rendimientos que las empresas más grandes ([Huberman y Kandel 1987](#)).

El tercer factor refleja el efecto del ratio Book no Market Equity (HML) que se calcula con el retorno de empresas de alto (HIGH) ratio menos las acciones de bajo (LOW) ratio; de acuerdo con la teoría de que las empresas con alto Ratio

Book to Market obtienen mayores retornos que las empresas que tienen bajo Ratio B/M. Este factor es un proxy de la rentabilidad donde las empresas de menor rentabilidad en largos periodos con menos utilidades tienden a tener un alto ratio B/M, en que los inversores exigen rendimientos esperados más altos para comprar estas acciones. Caso contrario sucede con empresas más sólidas, con largos periodos de utilidades. Este argumento lo confirman estudios realizados ([Chan y Chen 1991](#)) ([Chen y Zhang 1998](#)), donde el factor valor (HML), demuestra capacidad para explicar los rendimientos esperados con datos de la bolsa de Nueva York.

El modelo de cinco factores agrega los factores de RMW (Robust Minus Weak), que es la diferencia entre los retornos de portafolios diversificados con robusta y débil rentabilidad operacional; el factor CMA (Conservative Minus Agresive), que es la diferencia entre los retornos de los portafolios diversificados de las acciones de inversiones conservadores y agresivas de las empresas. El modelo Fama Cahart adiciona al modelo de Fama French de tres factores la variable de momemtum, que se conforma entre las empresas ganadoras y perdedoras en retornos WML (Winner minus Losers) en el período de estudio.

Para la identificación del mejor modelo de valoración de activos se someterán a análisis los principales modelos propuestos por Eugene Fama y Kenneth French ([Fama & French, 2015](#)) y el modelo de Fama Cahart de cuatro factores. Para la explicación de las variaciones de corte transversal de los rendimientos mensuales de los activos de las empresas, que forman parte del IPSA de la bolsa de valores de Santiago de Chile entre 2007 y octubre de 2021. Se analizarán todas las anomalías que se puedan detectar o rechazos en términos de significancia estadística, orientado a juzgar el desempeño de los modelos en términos relativos mediante el test estadístico GRS ([Gibbons, Ross y Shanken 1989](#)) y otros estadísticos como el coeficiente de determinación.

La pregunta de investigación que se responderá a partir de este análisis es: **¿Qué modelo tiene mejor desempeño en el mercado de valores de Chile?** Ahora bien, también este mercado reviste una atención especial, porque los fondos de pensiones de capitalización individual (AFP, Administradoras de Fondos de Pensiones), se invierten en buena proporción en el índice IPSA de la bolsa de valores de Santiago de Chile.

Las limitaciones que tiene este estudio es que se utilizan los datos mensuales de las empresas listadas en el IPSA (Índice de Precios Selectivos de Acciones), entre

enero de 2007 y octubre de 2021 y además se prueban los modelos a partir del modelo de valoración CAPM.

Como resultado se obtiene que el factor de tamaño (SMB) en el mercado, resulta ser el factor de riesgo más sólido con base en la significancia estadística en los portafolios creados, seguido por el factor de premio por riesgo (RM-RF), y en menor medida el factor de valor (HML), donde en situación de pandemia aporta como factor de riesgo, la variable de momentum (WML).

Por lo tanto, el trabajo concluye que en periodos sin pandemia se puede utilizar el modelo de Fama French de cuatro factores y Fama French de cinco factores, para obtener mejores rendimientos en la valoración de activos; sin embargo, en periodo con pandemia el modelo de cuatro factores es el de mejor desempeño. En consecuencia, en periodos de crisis sanitaria este modelo debe ser considerado.

4.3.-Revisión bibliográfica

En las primeras pruebas a los modelos en mercados desarrollados, se evidenciaron los problemas que tiene el CAPM original en la fijación y predicción de precios de los activos. Es por esta razón que en Fama y French ([Fama, Eugene; French, Kenneth, 1993](#)) proponen agregar dos factores de riesgo más al modelo CAPM, uno de ellos es el tamaño medido por medio de la capitalización bursátil (SMB), y el otro es la relación entre el valor libro de la empresa y su valor de mercado (HML).

Esta investigación determinó que estos dos factores capturan el riesgo y la ganancia en el precio de las acciones. Posteriormente, al mostrar que en otros mercados y a correr del tiempo el modelo fue evidenciando problemas en la determinación de los retornos esperados, por lo tanto, Carhart ([Carhart 1997](#)), introduce un nuevo factor y se conoce como modelo Carhart Fama French de cuatro factores, el cual agrega el nuevo factor denominado momentum (WML). Obteniendo como resultado que este factor aporta información en la predicción de precios en el mercado de fondos mutuos.

Otros estudios realizados indican que los fondos que obtuvieron ganancias entre 1975 y 1988, son consistentes con los fondos mutuos que son ganadores en el año anterior; por consiguiente, los fondos que han tenido un desempeño superior en los periodos anteriores mantienen un rendimiento similar en el corto plazo (entre uno y ocho trimestres) y de la misma forma los fondos mutuos perdedores

también siguen perdiendo en un periodo de corto plazo ([Hendricks, Patel y Zeckhauser 1993](#)). Esto también lo confirmaron otros estudios, reafirmando al factor de riesgo de momentum como un elemento importante en la fijación de precios ([Zheng 1999](#)).

Existen diversos estudios acerca del factor de ratio Book to Market, donde han demostrado por medio de la utilización de regresiones de corte transversal que la rentabilidad, el crecimiento de los activos y las acumulaciones se comportan como proxies para la rentabilidad e inversión esperada, y es considerado como factor para representar el efecto de los flujos de caja neto esperados de las empresas. ([Miller y Modigliani 1961](#)) ([Aharoni, Grundy y Zeng 2012](#)). Además de ser probada por Fama y French ([Fama y French 2006](#)).

Otros estudios concluyen que la rentabilidad medida por las ganancias brutas de las empresas que representan los activos, tienen el mismo poder de predicción que el Book to Market para los rendimientos promedios. Las empresas rentables generan rendimientos promedios más altos que las empresas no rentables, a pesar de tener en promedio menor ratio Book to Market y mayores capitalizaciones de mercado. ([Novy-Marx, 2013](#)) ([Chan y Faff 2005](#)).

La incorporación de otros factores en búsqueda de mejor rendimiento de los modelos de valoración, como el de liquidez (IMV), se utilizó en una investigación, donde encuentran evidencia empírica de que el factor tamaño, liquidez, y el valor en riesgo explican las variaciones de los retornos en regresiones de corte transversal, de los activos que componen el NYSE, Amex y Nasdaq, entre 1963 y 2001 ([Bali y Cakici 2004](#)).

En otras investigaciones analizan el factor q utilizando un modelo de cuatro factores, factor de mercado, de tamaño, de inversión, y de rendimiento sobre capital (ROE), denominado factor q. Este relaciona los retornos esperados con las características de la empresa, con el objeto de obtener la mayor de las anomalías que otros modelos que no hayan logrado descubrir, teniendo como hallazgo que incorporando el factor q, el modelo es más eficiente que el modelo de Fama-French de tres factores y el modelo de Cahart de cuatro factores. ([Hou, Kewei; Xue, Chen; Zhang, Lu, 2014](#)).

En sintonía con el modelo anterior, aparece el trabajo de Fama & French donde introducen el modelo de cinco factores, incorporan los siguientes factores de inversión (RMW) y de rentabilidad operacional (CMA). Por medio de la prueba estadística de GRS obtienen que el modelo explica los retornos entre un 71% y

94% en los activos de Estados Unidos entre el periodo de 1963 y 2013 ([Fama & French, 2015](#)).

Otro estudio en el mercado australiano utiliza, además de los factores de tamaño SMB y ratio Book to Market (HML), un factor de riesgo de default. Utilizando el modelo generalizado de momentos (GMM), planteándose la hipótesis de acuerdo de cómo este riesgo incide en el precio de los activos, agregando este factor al modelo original de Fama French tres factores, concluyendo que el modelo de Fama French de tres factores no captura el riesgo de default ([Gharghori, Chan y Faff 2007](#)).

Algunos estudios también abarcan conceptos actuales como la sustentabilidad de las organizaciones, en busca de la existencia de un precio mundial de sostenibilidad corporativa, incorporando un factor de sustentabilidad (SUS: es la diferencia mensual, entre los rendimientos ponderados por valor en las carteras de alto puntaje de sostenibilidad y el valor ponderado rentabilidad de las carteras de bajo, puntaje de sostenibilidad). Obteniendo como conclusión que aquellos inversionistas que tienen inversiones en empresas sostenibles pueden obtener retornos anormales ([Xiao, y otros 2013](#)).

En la línea de probar modelos o realizar variaciones a los existentes, existen estudios como los siguientes:

En el mercado indio, un mercado emergente por un periodo de quince años, prueban los modelos CAPM tradicional, de tres factores y cinco factores, concluyendo que el modelo de tres factores explica mejor los retornos promedios de las acciones ([Harshita y Surendra 2015](#)).

Otra variación que se aplicó al CAPM, es el CCAPM desarrollo por Rubinstein ([Rubinstein 1976](#)), quien postula que la variación de los rendimientos promedio puede explicarse por las diferencias en la exposición de las empresas al riesgo de consumo, según la modificación del modelo. Los activos que varían positivamente con el crecimiento del consumo (bienes durables y transables) son menos atractivos para los inversionistas, ya que en tiempos de crisis no ofrecen buena cobertura; por tanto, los inversionistas deben ser compensados con un alto rendimiento. ([Xiao, Yuchao; Faff, Robert; Gharghori, Philip; Min, Byoung-Kyu 2012](#)).

Para analizar los factores es importante situarse en mercados y espacio temporal. Eso queda plasmado en un estudio realizado sobre mercados de Japón, América

del Norte, Europa y Asia Pacífico. Para todos los mercados, excepto Japón, los factores de tamaño (SMB), rentabilidad operacional (RMW) y nivel de inversión (CMA), son relevantes en los aumentos de los retornos esperados. (Kubota y Takehara 2017).

También existen estudios controversiales en sentido de la aplicación de métodos estadísticos para comprobarlos, en los que se concluye que el comportamiento de los cambios en los precios no necesariamente se deben a la existencia de un mayor o menor riesgo en el mercado, se puede evidenciar que existen reacciones en los precios de los activos que no tienen concordancia con el nivel de riesgo sistemático (Lakonishok, Shleifer y Vishny 1994), en ese sentido existen estudios que aplican rendimientos de carteras clasificadas por atributos de acciones ordinarias para representar factores de riesgo en un modelo de valoración de activos, donde los atributos se eligen siguiendo una relación observada empíricamente con la sección transversal de retornos de acciones. Esta historia ha ilustrado, que, utilizando datos artificiales, estas carteras clasificadas por atributos que parecen ser factores de riesgo útiles. Pero al final se concluye que los atributos no tienen ninguna relación con la exposición al riesgo. (Ferson, Sarkissian y Simin 1999).

Un estudio realizado el mercado de valores de Chile, con datos mensuales comprendidos entre 1997 y 2007, aplicando el método generalizado de momentos (MGM) al modelo de un factor CAPM, utilizando carteras de igual ponderación como proxy para la cartera de mercado, concluyendo que con el método indicado y periodo de tiempo el modelo CAPM explica satisfactoriamente los retornos esperados (Díaz Contreras y Higuera Cartes 2012).

A lo largo de la historia de estos modelos de valoración, se han ido realizando estudios acerca de cuan válidos son los factores propuestos para obtener con mayor precisión los movimientos de los precios de los activos.

Uno de ellos utilizó datos mensuales de NYSE, AMEX y NASDAQ, entre diciembre de 1963 y 1993, obteniendo los siguientes hallazgos al aplicar el modelo de tres factores: una alta correlación entre el factor de tamaño (SMB) y el de ratio book to market (HML), indicando que el determinante del retorno de las acciones son las características de las acciones y no su riesgo. Así mismo también se observa que los inversores prefieren las acciones en crecimiento (Strong firms) ante las que crecen menos (Weak firms) y, por último, el factor beta de mercado no posee poder explicativo (Daniel y Titman 1997).

Otro estudio que prueba el modelo de tres factores emplea datos mensuales desde 1999 a 2010 en el mercado de valores de Amman (ASE), encuentra que ambos factores de tamaño y valor tienen un efecto positivo en los activos del mercado, validando el uso de este modelo en el periodo y mercado indicado y es mejor que el original de un factor CAPM. (Al-Mwalla y Karasneh 2011). Sin embargo, otro estudio en el mismo mercado que utilizó 84 empresas que cotizan en la bolsa de valores de Amman (ASE) durante el periodo desde 2011 a 2015, obtuvo como hallazgo que el modelo de cinco factores no explica los retornos del mercado en el periodo analizado, sugiriendo que pueden existir en ese periodo otros factores de riesgo que aportan a la explicación de los retornos de los activos. (Alrabadi y Alrabadi 2018).

Estudios acerca del modelo de tres factores en el mercado colombiano, en un periodo entre 2019 y 2012, dieron cuenta de que solo el factor de riesgo de tamaño de las empresas obtiene un mejor resultado en la obtención de los retornos. (Carmona Muñoz y Vera Leyton 2015)

Otro estudio en el mercado de valores de Estambul sometió activos de 18 empresas, con datos de 1995 a 2017, obteniendo como resultado que el factor de rentabilidad es positivo y estadísticamente significativo; sin embargo, el factor de inversión no obtiene significancia estadística. Finalmente concluye que no existe suficiente evidencia de que el modelo de cinco factores de Fama y French sea válido en el mercado (Feyyaz, Tayfun y Murat 2019).

En contraste a los puntos anteriores, existen otros estudios como el aplicado en el mercado de valores de India, con datos del periodo de 2005 y 2015, sometiendo a prueba al modelo CAPM de un factor y el de Fama French de tres factores, concluyendo que es más eficiente en la capacidad explicativa de las variaciones de los rendimientos de los activos, es el modelo de tres factores, además obtienen que el factor tamaño (SMB) es significativo en el mercado Indio, sin embargo, el factor de valor (HML) no es concluyente (Sobti 2016), por lo tanto es necesario tener en cuenta el mercado y el tiempo de aplicación para obtener que factor o modelo posee mejor rendimiento.

Otro estudio realizado en la bolsa de valores de Alemania probando el modelo de Fama French de cinco factores agregando el factor de momentum (WML), utilizó un periodo de datos mensuales desde 2002 a 2019, no encontrando evidencia significativa sobre el factor de rentabilidad y premio por riesgo. Comparando el modelo de Fama French de seis factores con el modelo de tres

factores, se revela que los factores adicionales no agregan poder explicativo significativo en el mercado de valores de Alemania en el periodo analizado (Dirkx y Peter 2020).

Otra investigación acerca de la validez del modelo de valoración de Fama French de tres factores aplicado en la bolsa de valores de Egipto, utilizando datos mensuales de 50 acciones entre 2014 y 2018, obtiene como hallazgo que el modelo de tres factores, consigue que el coeficiente beta (riesgo sistemático) sea insignificante, y los factores tamaño (SMB) y de valor (HML) resultan iguales a cero e insignificante, concluyendo que en ese periodo y mercado no existe relación entre rentabilidad esperada y los factores de riesgo indicados por Fama y French de tres factores (Abd-Alla y Sobh 2020).

En el mismo sentido, un estudio en el mercado de Vietnam investigó la redundancia del factor valor y el factor de rentabilidad. En este caso la investigación concluye que el modelo de cinco factores de Fama y French tiene más poder explicativo que el modelo de tres factores (Ryan, y otros 2021).

Un estudio en el mercado de valores japonés introduce al modelo de Fama y French de cinco factores un factor proveniente del capital humano, probando un modelo de seis factores, con datos mensuales de 24 años desde 1990 a 2017. Este aplica la prueba del estadístico de GRS, y confirma que este modelo tiene mayor rendimiento en la fijación de precios de los activos que el de tres factores, cinco factores y el de cuatro factores de Cahart.(Roy 2021).

Una investigación realizada en el mercado de valores de Shanghái, entre el periodo de 1994 a 2016, arroja que el modelo de Fama y French funciona mejor para valorar este mercado. Sin embargo, también visualiza que este modelo varía con el tiempo y en general obtiene algunos errores en la aplicación. También obtienen como hallazgo como en los otros estudios que el factor más consistente es el de tamaño de las empresas y el factor valor es más bien insignificante (Huang 2019).

Otros estudios indican que los modelos de valoración de activos factoriales generalmente funcionan mal en los mercados emergentes, donde la investigación se aboca en descubrir si es consecuencia de ignorar otras fuentes de riesgo, utilizando una muestra de 26 mercados de valores emergentes e incorporan un nuevo factor al modelo de Fama y French de cinco factores, que es el factor de descuento estocástico (SDF), este obtiene mejor bondad de ajuste para los mercados emergentes (González-Sánchez 2021).

Un estudio acerca de someter a prueba los modelos de tres y cinco factores de Fama y French en el periodo de julio de 2005 a junio de 2016 en el mercado de valores egipcio, concluyó que, si bien ambos modelos no pueden ser rechazados por su rendimiento, dejan variaciones sustanciales en los rendimientos que no son explicados, debido a sus bajos coeficientes de determinación (R^2); no obstante, descubren que los modelos sobreestiman los retornos en el mercado estudiado. (Ragab, Abdou y Sakr 2020).

Una investigación en el mercado de valores de Japón probó el modelo de Fama y French de cinco factores durante julio de 1990 y abril de 2020. Concluyó que los factores de mercado ($R_m - R_f$), tamaño (SMB) y valor (HML) son significativos en todas las carteras del estudio; no obstante, en los factores de rentabilidad (RMW) y de inversión (CMA), sólo son significativos en algunas carteras. (Liammukda, y otros 2020).

En los mercados emergentes latinoamericanos y asiáticos, mediante la aplicación de un estudio de los modelos de tres, cuatro y cinco factores, se encontró que el factor valor es redundante con los factores de rentabilidad e inversión. (Leite, Klotzle y Figueiredo, y otros 2018).

Otros estudios que prueban los modelos de Fama y French en un periodo de 1990 a 2020, donde cubren crisis financieras y la situación de emergencia sanitaria del COVID-19, utilizan como discriminador el coeficiente de determinación R^2 , concluyendo que el modelo de cinco factores obtiene el valor más alto del coeficiente de determinación, en la pandemia del COVID-19 y en otras crisis financieras comprendidas en el período (Horváth y Wang 2021). Otra investigación que evalúa el modelo de cinco factores obtiene como hallazgo que el modelo ofrece una mejor descripción de los rendimientos de las acciones de mercados emergentes que el modelo de tres factores, además descubren que el factor de rentabilidad no proporciona un buen rendimiento en la región asiática. (Foye 2018).

Es importante destacar también que se han ido incorporando factores ambientales, sociales y de gobernanza (ESG: Environmental, Social and Governance), explicando los rendimientos en la pandemia del COVID-19, que componen el índice SP&500, obteniendo como resultado que la adición del este factor al modelo factorial de Fama y French, ayuda significativamente a los demás factores del modelo en la explicación de los retornos de los activos (Díaz, Ibrushi y Zhao 2021).

4.4.-Metodología y datos

4.4.1.-Modelo Capital Asset Pricing Model (CAPM)

Este modelo desarrollado por Sharpe (Sharpe 1964) y complementado por Lintner (Lintner, 1965), es lineal y positivo entre la relación del activo y su covarianza con la rentabilidad de la cartera del mercado, obteniendo el máximo de los rendimientos con respecto a un riesgo. También relaciona los retornos esperados del activo con el rendimiento del mercado.

El modelo adopta los siguientes supuestos: Los inversionistas son aversos al riesgo, son maximizadores de utilidades, ningún inversionista tiene el poder suficiente para influir en los precios del mercado, el rendimiento de los activos y su covarianza tienen una distribución normal. En el mercado existe un activo libre de riesgo y este se comporta como un mercado perfecto y además no existe asimetría en la información de los agentes que participan en él.

El modelo es el siguiente:

$$R_i(E) = R_f + (R_m - R_f) \times \beta \quad 4.1$$

$$\beta = \frac{\text{Cov}(R_i, R_m)}{\text{Var}(R_m)} \quad 4.2$$

Donde: R_i : Es el retorno esperado de los activos, R_f : Es el retorno esperado del activo libre de riesgo, R_m : Es el retorno esperado del mercado, β : Corresponde al riesgo sistemático del mercado.

4.4.2.-Modelo Fama French Tres Factores

Esta propuesta se desarrolla en respuesta al bajo rendimiento de CAPM tradicional, adicionando dos factores explicativos de los retornos de los activos. La evidencia que obtuvieron los investigadores es que el factor tamaño de la empresa representado por la relación del valor bursátil (capital bursátil) y el valor libro (Ratio P/B) de las empresas, tienen incidencia en los rendimientos esperados de los activos (Fama, Eugene; French, Kenneth, 1993).

La lógica del factor tamaño es que las empresas más grandes obtienen menores retornos en promedio que las empresas de menor tamaño, existiendo una relación inversa en la teoría, en cambio, el factor ratio Book to Market las empresas que tienen mayor ratio poseen retornos en promedio mayores a las

empresas que tienen ratios más bajos, existiendo una relación directa entre ambas variables.

El modelo de tres factores de Fama French es el siguiente:

$$Y_{it} = \alpha_i + \beta_{i,MRP} \times MRP_t + \beta_{i,SMB} \times SMB_t + \beta_{i,HML} \times HML_t + \varepsilon_{it} \quad 4.3$$

Donde:

$Y_{it} = R_{it} - R_{rf}$, Corresponde al retorno en exceso del portafolio i en el tiempo t, $MRP_t = R_{Mt} - R_{rf}$, Es el exceso de retorno de mercado en el tiempo t, $SMB_t = R_{St} - R_{Bt}$, Es la diferencia entre el promedio de los retornos sobre los portafolios "Small" (SL, SM, SH) y los portafolios "Big" (BL, BM, BH), $HML_t = R_{Ht} - R_{Lt}$, Es la diferencia entre el promedio de los retornos sobre los portafolios "High" ratio P/B (SH, BH) y los portafolios "Low" ratio P/B (SL, BL), R_{rf} , representa la tasa libre de riesgo, R_{it} , corresponde a la tasa de retorno de cada uno de los portafolios en el tiempo t, β_{iP} , corresponde al riesgo sistemático de los portafolios en el tiempo t, α_i , corresponde al retorno anormal de los portafolios y ε_{it} corresponde al término de error.

4.4.3.-Modelo de Fama Cahart de Cuatro Factores

El modelo propuesto por [Cahart \(1997\)](#) es similar al de Fama y French de tres factores, quién añade una variable más: El factor momentum, es decir, el retorno medio de las carteras de las empresas que en el periodo analizado obtienen ganancias en el mercado (Winner) menos el retorno medio de las carteras de la empresa que obtienen perdidas (Looser). Está relacionado con el ciclo económico. El modelo está representado por:

$$Y_{it} = \alpha_i + \beta_{i,MRP} \times MRP_t + \beta_{i,SMB} \times SMB_t + \beta_{i,HML} \times HML_t + \beta_{i,MOM} \times WML_t + \varepsilon_{it} \quad 4.4$$

Donde:

$Y_{it} = R_{it} - R_{rf}$, Corresponde al retorno en exceso del portafolio i en el tiempo t, $MRP_t = R_{Mt} - R_{rf}$, Es el exceso de retorno de mercado en el tiempo t, $SMB_t = R_{St} - R_{Bt}$, Es la diferencia entre el promedio de los retornos sobre los portafolios "Small" (SL, SM, SH) y los portafolios "Big" (BL, BM, BH), $HML_t = R_{Ht} - R_{Lt}$, Es la diferencia entre el promedio de los retornos sobre los portafolios "High" ratio P/B (SH, BH) y los portafolios "Low" ratio P/B (SL, BL), WML corresponde a la

diferencia entre empresas que obtienen mayores retornos y las que obtienen menos retorno en el periodo t y ε_{it} corresponde al término de error.

4.4.4.-Modelo Fama French Cinco Factores

Como se indicó anteriormente en el modelo de tres factores de Fama y French, se captura la relación entre el promedio de los retornos y el tamaño bursátil de las empresas y la relación de estos retornos entre el ratio Book to Market de las empresas adicionalmente otros investigadores (Novy-Marx, 2013) observan que el modelo de Fama French tres factores está incompleto y no puede explicar correctamente las variaciones de retornos promedios. Ellos agregaron dos variables relacionadas con la rentabilidad y la inversión de las empresas, posteriormente los autores originales modifican el modelo y testean tres modelos, CAPM, CAPM tres factores y Cinco Factores (Fama & French, 2015), obteniendo como resultado y conclusión que el modelo de cinco factores tiene mejor rendimiento que los otros antes propuestos según un estudio para la bolsa NYSE de Estados Unidos, en un periodo testeado de entre julio de 1963 y diciembre de 2013.

El modelo está representado de la siguiente forma:

$$Y_{it} = \alpha_i + b_{i,MRP} \times MRP_t + s_{i,SMB} \times SMB_t + h_{i,HML} \times HML_t + r_{i,RMW} \times RMW_t + c_{i,CMA} \times CMA_t + \varepsilon_{it} \quad 4.5$$

Donde:

$Y_{it} = R_{it} - R_{rf}$, Corresponde al retorno en exceso del portafolio i en el tiempo t, $MRP_t = R_{Mt} - R_{rf}$, es el exceso de retorno de mercado en el tiempo t, $SMB_t = R_{St} - R_{Bt}$, es la diferencia entre el promedio de los retornos sobre los portafolios "Small" (SL, SM, SH) y los portafolios "Big" (BL, BM, BH). $HML_t = R_{Ht} - R_{Lt}$, es la diferencia entre el promedio de los retornos sobre los portafolios "High" ratio P/B (SH, BH) y los portafolios "Low" ratio P/B (SL, BL), $RMW_t = R_{Rt} - R_{Wt}$, es la diferencia entre el promedio de los retornos sobre los portafolios "Robust" (SR, BR) y los portafolios "Weak" (SW, BW), $CMA_t = R_{Ct} - R_{At}$, es la diferencia entre el promedio de los retornos sobre los portafolios "Conservative" (SC, BC) y los portafolios "Agresive" (SA, BA), R_{rf} , representa la tasa libre de riesgo, R_{it} , corresponde a la tasa de retorno de cada uno de los portafolios en el tiempo t, β_{iP} , corresponde al riesgo sistemático de los portafolios en el tiempo t, α_i ,

corresponde al retorno anormal de los portafolios, ε_{it} corresponde al término de error.

En este modelo se agrega el factor RMW (Robust Minus Weak), es la diferencia entre los retornos de portafolios diversificados con robusta y débil rentabilidad, y el factor CMA (Conservative Minus Agresive), que es la diferencia entre los retornos de los portafolios diversificados de las acciones de inversiones conservadores y agresivas de las empresas. Si las exposiciones de los cinco factores, b_i , s_i , h_i , r_i y c_i , captura todas las variaciones de los retornos esperados, el intercepto α_i en el modelo es cero para todas las acciones y portafolios i .

Fama y French sugieren dos interpretaciones acerca de la hipótesis del intercepto igual a cero, la primera propuesta de media varianza eficiente tangente con el portafolio, donde todos los precios de los activos combinan con el activo libre de riesgo, el portafolio de mercado, SMB, HML, RMW, y CMA. (Fama & French, 2015).

4.4.5.-Obtención de los factores de riesgo

El factor tamaño se obtiene de acuerdo a la capitalización bursátil de cada empresa listada en el índice IPSA para el caso de Chile, a diferencia del estudio original de Fama French que se utilizaron percentiles 30 y 70, en este caso por el tamaño del índice chileno, se utilizará el término central, para separar los activos en dos grupo Small y Big; por lo tanto, el factor se obtendrá entre la diferencia del promedio anual de los retornos de las empresas que poseen un pequeño valor bursátil y las empresas que tienen un gran capital bursátil.

El factor B/M (Book to Market Ratio), se obtiene con el monto del patrimonio (B) según el balance al 31 de diciembre de cada año de la serie temporal por cada empresa, que tiene sus acciones en el índice IPSA, con la relación de monto correspondiente a la capitalización de mercado de cada empresa (M), representado por la siguiente ecuación:

$$\frac{B}{M} = \frac{B_{t-1}}{M_{t-1}} \quad 4.6$$

Luego de obtener los ratios se obtiene los dos grupos por medio del término central (mediana) y se obtiene dos grupos "High" los que tienen alto ratio B/M y "Low" los activos de bajo ratio B/M.

El factor RMW se obtiene a través de la rentabilidad operacional de las empresas que tienen acciones en el índice IPSA, este ratio se obtiene a partir de la relación del EBITDA (Ganancias antes de interés, impuestos, depreciación y amortizaciones) y del valor libro del patrimonio contable (B) y está representado por:

$$OP_{t-1} = \frac{EBITDA_{t-1}}{B_{t-1}} \quad 4.7$$

Una vez calculado la rentabilidad operacional se utiliza el término central (mediana) donde se obtienen dos grupos: "Robust" que corresponde a aquellas empresas que poseen mayor rentabilidad y "Weak" que son aquellas organizaciones que poseen bajas rentabilidades.

El factor CMA, se obtiene por el ordenamiento de las empresas de acuerdo con el total de activos que presentan en el balance al final de cada año de las empresas listadas en el índice IPSA ordenadas de acuerdo con la mediana. Con el objetivo de obtener dos grupos: "Agresive", que son aquellas empresas que mantienen una mayor inversión promedio entre los años estudiados y, "Conservative" que son las de menor monto promedio de activos en periodo de estudio, el cálculo está dado por la siguiente ecuación:

$$INV_{t-1} = \frac{A_{t-1} - A_{t-2}}{A_{t-2}} \quad 4.8$$

Donde: INV_{t-1} = Inversiones en período $t - 1$, A_{t-1} =

Activos totales en período $t - 1$, A_{t-2} = Activos totales en período $t - 2$.


Para probar el modelo de valoración CAPM se realiza en 1973 una forma de hacer una prueba por (Fama y MacBeth 1973), que se realizó con acciones de la bolsa de Nueva York NYSE. Este modelo asume que el mercado de capitales es perfecto y no existen oferentes o demandantes que puedan influir en el precio de los activos, no existen costos de transacción, como tampoco de información, los que invierten son aversos al riesgo y racionalmente buscan una combinación de sus activos (portafolios) que maximicen sus retornos esperados, teniendo presente que a mayor riesgo mayor retorno potencial (no es garantía la elección de mayor riesgo, mayor retorno). Estos retornos esperados y el riesgo tanto de activos individuales como de portafolios se relacionan de forma lineal. Otro elemento del modelo es el riesgo sistemático (beta) que corresponde a la medida de riesgo del activo.

Datos utilizados.

Bolsa de Valores de Santiago de Chile.

Desde 1893, la Bolsa de Santiago inicia sus actividades para conformar un mercado de valores para Chile, La bolsa posee dos índices IGPA (Índice General de Precios de Acciones) e IPSA (Índice de Precios Selectivo de Acciones).


Figura 4.1. Montos Transados en MMUSD entre 2007-2020, fuente: Bolsa de Valores de Santiago. .
Software utilizado Rstudio.



La figura 4.1, muestra que el mercado durante el año 2020 registró transacciones totales por US\$ 34.441 millones de dólares, anotando una disminución del 17% respecto a las transacciones registradas el año anterior.

La figura 4.2, muestra la evolución mensual del índice IPSA entre 2007 y 2021.

Figura 4.2: Evolución del precio mensual del Índice IPSA, Fuente: Bolsa de Valores de Santiago. .
Software utilizado Rstudio.



En la tabla 4.1, se puede apreciar las acciones del índice IPSA, donde también se muestra la industria a la que pertenecen, los precios que se utilizan son mensuales y comprenden los periodos de enero 2007 a octubre de 2021.

Activo	Industria	Activo	Industria
BCI	Banca	SM-CHILE-B	Holding
BSANTANDER	Banca	MASISA	Industrial
CHILE	Banca	SK	Industrial
ITAU CORP	Banca	SMSAAM	Industrial
SECURITY	Banca	VAPORES	Industrial
CAP	Commodities	CENCOSUD	Retail
CPMC	Commodities	FALABELLA	Retail
COPEC	Commodities	FORUS	Retail
SQM-B	Commodities	NUEVAPOLAR	Retail
BESALCO	Const. & Inmob.	RIPLEY	Retail
PARAU CO	Const. & Inmob.	SONDA	TI
SALFACORP	Const. & Inmob.	ENTEL	Telecomunicaciones
ANDINA-B	Consumo	LTM	Transporte Aéreo
CCU	Consumo	AESGENER	Utilities
CONCHATORO	Consumo	AGUAS-A	Utilities
EMBONOR-B	Consumo	COLBUN	Utilities
ANTARCHILE	Holding	ECL	Utilities
IAM	Holding	ENELAM	Utilities
ILC	Holding	ENELCHILE	Utilities
ORO BLANCO	Holding	ENELGXCH	Utilities

Tabla 4.1: Acciones por Industria de Empresas que componen el índice IPSA

4.5.-Metodología

El modelo de tres factores de (Fama, Eugene; French, Kenneth, 1993), fue diseñado para capturar la relación entre rentabilidad promedio y el tamaño de las empresas (Capitalización de mercado, precio multiplicado por las acciones en circulación) (SMB) y la relación entre los retornos promedios y el factor valor B/M. (HML) corrigiendo el modelo de un factor que no explicaban estos riesgos. Al evidenciar falta de factores de riesgo (Fama & French, 2015), agregaron dos factores más, proponiendo el modelo de Fama y French de cinco factores. Incluyen los factores de rentabilidad operacional RMW (Robust minus Weak), bajo la lógica que las empresas que presentan mayor rentabilidad operacional obtienen mayores retornos de aquellas que tienen menor rentabilidad operacional y el factor de inversión CMA (Conservative minus Agresive), bajo la premisa que las empresas más conservadores en inversión obtienen mayores retornos en el corto plazo, de las empresas que más invierten. Los investigadores encuentran varias anomalías del modelo de tres factores. Los autores incorporan los factores analizados por otros investigadores como (Novy-Marx, 2013), quien identifica que la rentabilidad o beneficios esperados están fuertemente relacionada con los retornos esperados y (Aharoni, Grundy, & Zeng, 2012), documentan en su trabajo, pero con más debilidad estadística, una relación fiable entre la inversión y los retornos promedios. En el trabajo de investigación de (Fama & French, 2015) prueban los factores dando cuenta que el modelo anterior de (Fama, Eugene; French, Kenneth, 1993), proponiendo el ajuste del modelo, agregando estos dos factores.

El proceso que realiza (Fama & French, 2015), para probar los factores de rentabilidad operacional e inversión, es el siguiente:

Para examinar si los detalles de la construcción de factores son importantes en las pruebas de los modelos de fijación de precios de activos, se utilizan tres conjuntos de factores para capturar los patrones en los rendimientos promedio, en la figura 4.3, se muestra el resumen de la metodología aplicada por Fama & French. Donde se utilizan ordenamientos independientes para asignar activos a dos grupos de tamaño y a tres grupos ordenados por el factor valor (B/M), rentabilidad operativa (Op) e inversión (Inv). Las carteras dependientes que son definidas por intersecciones de dos grupos, El primero siempre describe el grupo Tamaño, pequeño (S) o grande (B). En los tipos 2 x 3 y 2 x 2, el segundo describe el grupo B/M, alto (H), neutral (N) o bajo (L), el grupo OP, robusto (R), neutral

(N) o débil (W), o el grupo Inv, conservador (C), neutral (N) o agresivo (A). En las clasificaciones $2 \times 2 \times 2 \times 2$, el segundo carácter es el grupo B/M, el tercero es el grupo Op y el cuarto es el grupo Inv. Los factores son SMB (pequeño menos grande), HML (B/M alto menos bajo), RMW (Op robusto menos débil) y CMA (Inv conservador menos agresivo).


Figura 4.3: Resumen de composición de portafolios realizados en la revisión del modelo de cinco factores, Fuente: (Fama & French, 2015)

Sort	Breakpoints	Factors and their components
2×3 sorts on Size and B/M, or Size and OP, or Size and Inv	Size: NYSE median	$SMB_{B/M} = (SH + SN + SL)/3 - (BH + BN + BL)/3$ $SMB_{OP} = (SR + SN + SW)/3 - (BR + BN + BW)/3$ $SMB_{Inv} = (SC + SN + SA)/3 - (BC + BN + BA)/3$ $SMB = (SMB_{B/M} + SMB_{OP} + SMB_{Inv})/3$
	B/M: 30th and 70th NYSE percentiles OP: 30th and 70th NYSE percentiles Inv: 30th and 70th NYSE percentiles	$HML = (SH + BH)/2 - (SL + BL)/2 = [(SH - SL) + (BH - BL)]/2$ $RMW = (SR + BR)/2 - (SW + BW)/2 = [(SR - SW) + (BR - BW)]/2$ $CMA = (SC + BC)/2 - (SA + BA)/2 = [(SC - SA) + (BC - BA)]/2$
2×2 sorts on Size and B/M, or Size and OP, or Size and Inv	Size: NYSE median	$SMB = (SH + SL + SR + SW + SC + SA)/6 - (BH + BL + BR + BW + BC + BA)/6$ $HML = (SH + BH)/2 - (SL + BL)/2 = [(SH - SL) + (BH - BL)]/2$
	OP: NYSE median Inv: NYSE median	$RMW = (SR + BR)/2 - (SW + BW)/2 = [(SR - SW) + (BR - BW)]/2$ $CMA = (SC + BC)/2 - (SA + BA)/2 = [(SC - SA) + (BC - BA)]/2$
$2 \times 2 \times 2 \times 2$ sorts on Size, B/M, OP, and Inv	Size: NYSE median	$SMB = (SHRC + SHRA + SHWC + SHWA + SLRC + SLRA + SLWC + SLWA)/8$ $- (BHRC + BHRA + BHWC + BHWA + BLRC + BLRA + BLWC + BLWA)/8$
	B/M: NYSE median	$HML = (SHRC + SHRA + SHWC + SHWA + BHRC + BHRA + BHWC + BHWA)/8$ $- (SLRC + SLRA + SLWC + SLWA + BLRC + BLRA + BLWC + BLWA)/8$
	OP: NYSE median	$RMW = (SHRC + SHRA + SLRC + SLRA + BHRC + BHRA + BLRC + BLRA)/8$ $- (SHWC + SHWA + SLWC + SLWA + BHWC + BHWA + BLWC + BLWA)/8$
	Inv: NYSE median	$CMA = (SHRC + SHWC + SLRC + SLWC + BHRC + BHWC + BLRC + BLWC)/8$ $- (SHRA + SHWA + SLRA + SLWA + BHRA + BHWA + BLRA + BLWA)/8$

Si bien en el estudio de Fama French cinco factores se utilizaron matrices de 2×3 2×2 y $2 \times 2 \times 2 \times 2$ para generar los portafolios a testear considerando la cantidad de activos que posee el índice IPSA, se construirá con matrices 2×2 igualmente ponderadas y diversificadas.


La figura 4.3, muestra el tamaño de grandes y pequeñas empresas según capital bursátil en cada año, desde 2007 a 2020. Al obtener el promedio anual del tamaño bursátil se utiliza como punto de corte la mediana. Los datos fueron obtenidos de memorias de las empresas que están depositadas en la Comisión del Mercado Financiero de Chile (CMF).

Figura 4.4. Tamaño bursátil de los títulos del IPSA. (Separación de tamaño utilizando la mediana de la capitalización). Software utilizado Rstudio.




La figura 4.4, muestra el factor ratio book to market ordenado de mayor a menor ratio, también son separados en dos grupos de acuerdo con el corte por la mediana.

Figura 4.5: Ratio Book to Market de los títulos del IPSA (Separación de alto o bajo utilizando la mediana del ratio book to market). . Software utilizado Rstudio.




La figura 4.5, muestra el factor de rentabilidad operacional ordenado de mayor a menor ratio, también son separados en dos grupos por corte en la mediana.

Figura 4.6. Factor de rentabilidad operacional de los títulos del IPSA (Separación de alto o bajo utilizando la mediana de la rentabilidad operacional). . Software utilizado Rstudio.




La figura 4.6, muestra el factor de inversión ordenado de mayor a menor ratio que también son separados en dos grupos por medio de la mediana.

Figura 4.7: Factor de inversión de los títulos del IPSA (Separación de alto o bajo utilizando la mediana de la rentabilidad operacional). . Software utilizado Rstudio.



La figura 4.7, muestra el factor de momentum ordenado de mayor a menor ratio, también son separados en dos grupos por medio de la mediana.

Figura 4.8: Factor de momentum de los títulos del IPSA (Separación de alto o bajo utilizando la mediana de la rentabilidad operacional). . Software utilizado Rstudio.



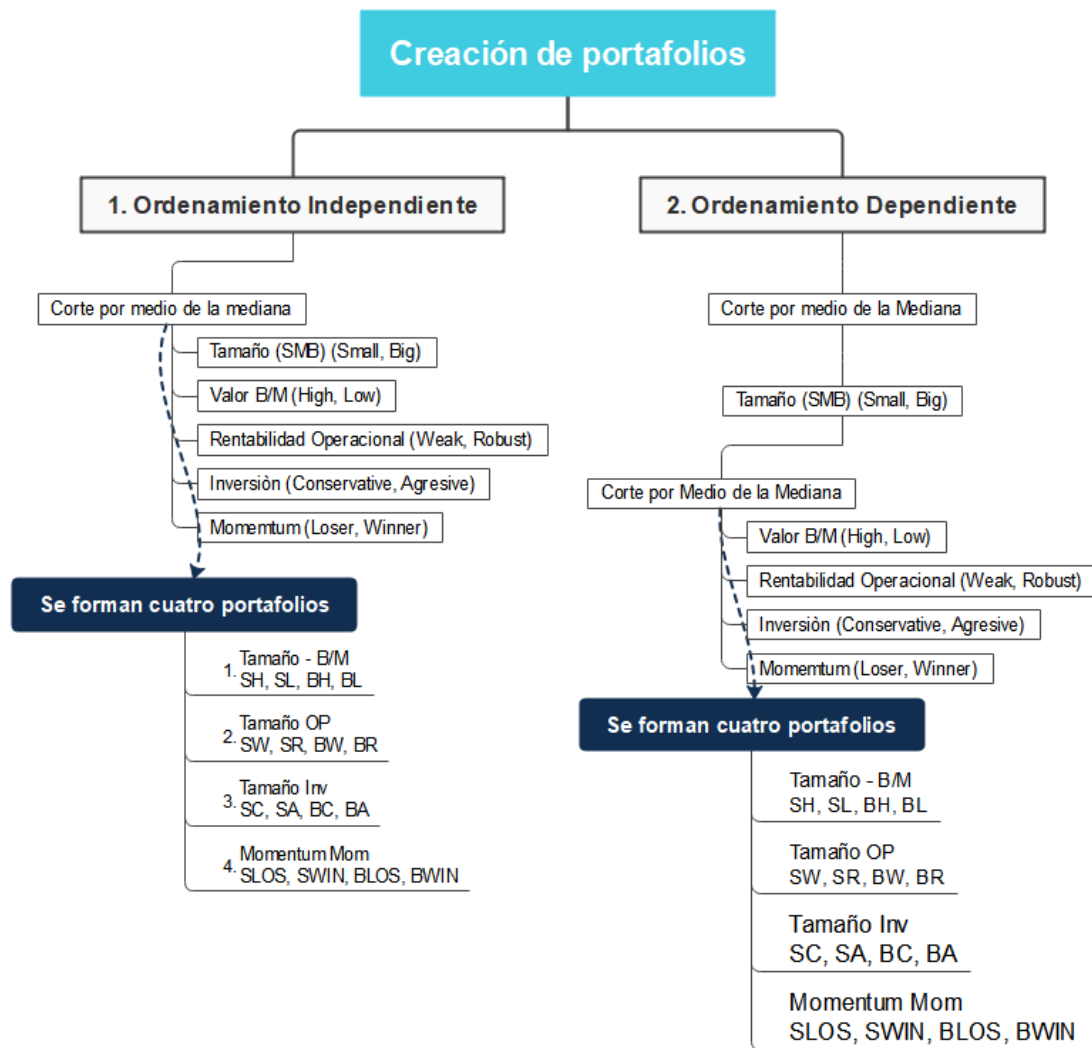
En la tabla 4.2, se muestra la intersección de los grupos formados en forma independiente y dependientes se obtiene cuatro portafolios para cada factor. El ordenamiento dependiente se realiza primero los dos grupos de los factores, por medio de la mediana, originalmente (Fama & French, 2015), se utiliza percentiles 30 y 70

Ordenamiento	Punto de Corte	Factor y sus componentes
Ordenamiento de matrices 2x2	Tamaño: Mediana	$SMB = \frac{SH + SL + SR + SW + SC + SA}{6}$
Tamaño y B/M, o Tamaño y OP, o Tamaño e Inv.	B/M: Mediana OP: Mediana Inv: Mediana	$- \frac{BH + BL + BR + BW + BC + BA}{6}$
Tamaño y Mom.	Mom: Mediana	$HML = \frac{SH + BH}{2} - \frac{SL + BL}{2} = \frac{(SH - SL) + (BH - BL)}{2}$
		$RMW = \frac{SR + BR}{2} - \frac{SW + BW}{2} = \frac{(SR - SW) + (BR - BW)}{2}$
		$CMA = \frac{SC + BC}{2} - \frac{SA + BA}{2} = \frac{(SC - SA) + (BC - BA)}{2}$
		$WML = \frac{SWIN + BWIN}{2} - \frac{SLOS + BLOS}{2}$

Tabla 4.2: Resumen de cómo se elaboran los factores en ambos ordenamientos de los portafolios.


En la figura 4.8, muestra el diagrama de la metodología, donde se obtienen dos grupos de portafolios. Por un lado, los dependientes, que son la intersección de los dos grupos del factor tamaño, con la intercepción de los otros grupos de factores, obteniendo doce portafolios (seis por cada intercepción). Para los portafolios independientes se realiza el mismo proceso, pero primero se obtiene dos grupos por el factor tamaño y luego, al interior de cada uno de los grupos, se interceptan con los demás factores en estudio.

Figura 4.9. Diagrama que describe como se configuran los portafolios de este estudio, fuente: elaboración propia.




En la figura 4.9, se observa el retorno promedio mensual acumulado de los portafolios independientes, de acuerdo con los factores sometidos en estudio, entre enero 2007 y octubre de 2021.

Figura 4.10. Retornos de los factores construidos para portafolios independiente. Fuente: elaboración propia. Software utilizado Rstudio.



En la figura 4.10, se observa el retorno promedio mensual acumulado de los portafolios dependientes, de acuerdo con los factores sometidos en estudio, entre enero de 2007 y octubre de 2021.

Figura 4.11: Retornos de los factores construidos para portafolios dependiente, fuente: elaboración propia. Software utilizado Rstudio.



Se puede visualizar en la figura 4.9, una clara diferencia del factor tamaño (SMB) con respecto a los demás factores, mostrando mayor volatilidad de acuerdo con la respuesta de la situación económica del país relativamente igual al factor de mercado (Rm-Rf). A diferencia del ordenamiento dependiente que muestra la figura 10, los retornos resultan negativos en todo el periodo.

El factor tamaño en ambos ordenamientos es inverso a los demás factores y sigue una tendencia similar a la del factor de mercado (Rm-Rf), donde se aprecia que el factor de rentabilidad operacional (CMA) va en sentido inverso (negativo) en ambos ordenamientos de los portafolios y en el portafolio dependiente el factor de mayor rendimiento es de ratio B/M (HML). Con respecto a factor de riesgo de Momentum (WML), ambos ordenamientos presentan en todo el periodo retornos positivos.

4.5.1.-Test GRS

Cuando se supone que un activo libre de riesgo está disponible y los factores son rendimientos excesivos de las carteras negociables, las primas de riesgo del factor pueden identificarse por separado.

Las restricciones de precios de activos son:

$$H_{01}: \alpha_i = 0, \quad i = 1, \dots, N$$

En el caso del modelo de un solo factor, el exceso de rendimiento de mercado tiene restricciones conocidas para regresiones univariadas por medio del método de mínimos cuadrados ordinarios (MCO), donde proporcionan estimaciones de alfa y beta para cada activo del mercado, en donde alfa (intercepto) debería ser cercano a cero, bajo el supuesto de normalidad y donde los residuos de la regresión son idénticos e independientemente distribuidos.

Esta prueba contrasta el supuesto de que los errores están distribuidos en una normal, sigue la siguiente distribución de F:

$$\frac{T - N - K}{N} \frac{\hat{\alpha}' \hat{\Sigma}^{-1} \hat{\alpha}}{1 + \bar{F}' \hat{\Omega}^{-1} \bar{F}} \sim F_{N, T-N-K}(\eta) \quad 4.9$$

Donde \bar{F} y $\hat{\Omega}$ representan las matrices de covarianzas de los excesos de retornos, sobre los K portafolios en referencia, la distribución exacta de pruebas finitas, $F_{N, T-N-K}$, es la distribución F con grados de libertad N y T-N-1 y el parámetro de no linealidad $\eta = [T/(11 + \bar{F}' \hat{\Omega}^{-1} \bar{F})] \hat{\alpha}' \hat{\Sigma}^{-1} \hat{\alpha}$. Bajo el nulo, $\eta = 0$, pero en relación con la ecuación 4.9.

En el caso especial de un modelo, un factor, $K = 1$, cuando el factor es el exceso de rendimiento en un índice de mercado. (R_p).

Se debe tener en cuenta que el estadístico se utiliza para probar la hipótesis nula de que todos los interceptos (alfas) son igual a 0, por lo que mientras menor sea el t-estadístico, mayor el p-value asociado, si este valor es menor que 10% se rechaza H_0 de que todos los alfas son iguales a 0.

La primera columna muestra el t-estadístico de la prueba GRS.

$$GRS = \frac{T - N - K}{N} \left(\frac{\left[\frac{\sqrt{1 + \hat{\delta}_q^2}}{\sqrt{1 + \hat{\delta}_p^2}} \right]^2}{1} - 1 \right) \quad 4.10$$

Donde $\hat{\delta}_p^2$ es el ratio Sharpe de R_p y $\hat{\delta}_q^2$ es el ratio Sharpe de los portafolios eficientes ex post, es decir, la frontera de portafolio está formada por todos los retornos obtenidos por los activos. La media de la muestra ex post y la matriz de covarianza como los parámetros verdaderos. Por lo tanto, la prueba GRS captura las desviaciones relativas de la cartera dado el retorno de la cartera ex post portafolio eficiente, en términos de las proporciones de Sharpe. Un valor GRS más alto implica que el retorno se desvía más de la eficiencia ex post y, por lo tanto, H_1 será rechazado (Gibbons, Ross y Shanken 1989).

Sharpe Ratio

$$\text{Sharpe Ratio} = \frac{R_p - R_f}{\sigma_p} \quad 4.11$$

Donde: R_p : Retorno del portafolio, R_f : Tasa libre de riesgo, σ_p : Desviación estándar del exceso de retorno del portafolio.

La regla de decisión por el lado de significancia estadística, si el t-estadístico es igual a cero, mayor es el p-value asociado. Si el P-value es menor que 10% se rechaza la hipótesis nula (H_0), es decir, se rechaza que los interceptos del modelo (alfa) sean igual a cero.

4.6.-Resultados

		Portafolios Independientes		Portafolios Dependientes	
Período completo					
Panel A:	HML	Low	High	Low	High
	Small	-0,28%	-0,29%	-0,66%	-0,03%
	Big	-0,28%	-0,10%	-0,21%	-0,15%
Periodo sin Pandemia					
	Small	-0,05%	-0,08%	-0,52%	0,26%
	Big	-0,08%	0,12%	-0,10%	0,16%
Período completo					
Panel B:	RMW	Weak	Robust	Weak	Robust
	Small	-0,26%	-0,35%	-0,75%	0,07%
	Big	-0,34%	-0,05%	-0,06%	-0,33%
Periodo sin Pandemia					
	Small	-0,07%	-0,12%	-0,58%	0,34%
	Big	-0,15%	0,18%	0,11%	-0,08%
Período completo					
Panel C:	CMA	Conservative	Agresive	Conservative	Agresive
	Small	-0,32%	-0,30%	-0,36%	-0,37%
	Big	-0,20%	-0,19%	-0,17%	-0,20%
Periodo sin Pandemia					
	Small	-0,12%	-0,07%	-0,15%	-0,15%
	Big	0,01%	0,01%	-0,07%	0,13%
Período completo					
Panel D:	WML	Winner	Looser	Winner	Looser
	Small	-0,24%	-0,36%	-0,32%	-0,45%
	Big	-0,09%	-0,39%	-0,17%	-0,47%
Periodo sin Pandemia					
	Small	-0,04%	-0,14%	0,47%	-0,70%
	Big	0,16%	-0,23%	0,26%	-0,18%

Tabla 4.3: Retornos promedios de los portafolios conformados con factores del IPSA

De acuerdo con la tabla 4.3, si vemos el Panel A: Para el factor HML (Ratio) todos los portafolios independientes obtienen retornos negativos en el periodo completo. Sin embargo, sacando el periodo de pandemia, se obtienen promedios positivos en empresas grandes, ratio alto y en ordenamiento dependiente, tanto en empresas pequeñas y grandes con ratio alto de HML. Esto es concordante con

la teoría de que las empresas con alto ratio y de gran tamaño obtengan mayores retornos.

En el panel B: el factor RMW (Rentabilidad operacional), se aprecia que en periodo completo no es coherente con la teoría que empresas grandes o pequeñas, con rentabilidad operacional obtengan mayores retornos. Sacando el periodo de pandemia, se obtiene en ordenamiento independiente un mayor retorno de que las compañías con mayor rentabilidad operacional y de tamaño grande coherente con la teoría.

En el panel C: Para los portafolios tanto independientes y dependientes, los retornos promedios del período estudiado para el factor de inversión (CMA), son más bien variables. El comportamiento en rendimientos mensuales de los portafolios, donde obtienen mayor retorno las empresas de tamaño pequeño y de inversiones conservadores (-0,17%), no es un comportamiento concordante con la teoría que indica que las empresas grandes con inversión agresiva obtiene mayores retornos; no obstante, se comporta más acorde con la teoría sacando el período de pandemia.

En el panel D: En ambos ordenamientos de portafolios, los menores retornos se obtienen en los portafolios perdedores en retorno (-0,39%, -0,47%), y los mayores retornos lo obtienen las empresas grandes y ganadoras en retornos (-0,09%, -0,17%), concordante con la teoría de igual forma se aprecia este comportamiento en el período sin pandemia.

Período completo						
	Rm-Rf	SMB	HML	RMW	CMA	WML
Rm-Rf	1,00					
SMB	0,23	1,00				
HML	-0,07	-0,13	1,00			
RMW	-0,18	0,02	0,58	1,00		
CMA	-0,36	-0,13	-0,19	0,25	1,00	
WML	-0,08	-0,10	0,51	0,37	-0,14	1,00
	Rm-Rf	SMB	HML	RMW	CMA	WML
Promedio	0,11%	-0,17%	0,35%	-0,01%	-0,27%	0,69%
Desv. Stand.	4,89%	3,42%	2,52%	3,15%	2,52%	2,63%
Probabilidad	0,20	0,00	0,06	0,00	0,80	0,00
Período sin Pandemia						
	Rm-Rf	SMB	HML	RMW	CMA	WML

Rm-Rf	1,00					
SMB	-0,09	1,00				
HML	0,24	0,02	1,00			
RMW	-0,19	-0,02	-0,11	1,00		
CMA	-0,27	-0,06	0,05	0,54	1,00	
WML	-0,19	-0,01	-0,03	0,51	0,34	1,00
	Rm-Rf	SMB	HML	RMW	CMA	WML
Promedio	0,20%	0,07%	-0,16%	0,52%	0,09%	0,80%
Desv. Stand.	4,40%	0,45%	3,22%	2,37%	3,08%	2,57%
Probabilidad	0,48	0,00	0,00	0,68	0,01	0,00

Tabla 4.4: Matriz de correlación portafolios dependientes. Software utilizado Eviews.

Período completo						
	Rm-Rf	SMB	HML	RMW	CMA	WML
Rm-Rf	1,00					
SMB	0,94	1,00				
HML	0,01	0,00	1,00			
RMW	-0,14	-0,01	0,31	1,00		
CMA	-0,35	-0,35	-0,49	0,00	1,00	
WML	-0,10	-0,02	-0,02	0,14	-0,11	1,00
	Rm-Rf	SMB	HML	RMW	CMA	WML
Promedio	0,11%	-0,49%	0,09%	0,01%	-0,10%	0,21%
Desv. Stand.	4,89%	11,33%	0,87%	0,94%	0,76%	1,14%
Probabilidad	0,20	0,00	0,00	0,00	0,70	0,00
Período sin Pandemia						
	Rm-Rf	SMB	HML	RMW	CMA	WML
Rm-Rf	1,00					
SMB	0,94	1,00				
HML	0,01	-0,02	1,00			
RMW	-0,17	-0,03	0,27	1,00		
CMA	-0,34	-0,33	-0,48	0,04	1,00	
WML	-0,09	0,04	0,13	0,25	-0,25	1,00
	Rm-Rf	SMB	HML	RMW	CMA	WML
Promedio	0,20%	-0,07%	0,08%	0,02%	-0,13%	0,24%
Desv. Stand.	4,40%	10,15%	0,82%	0,93%	0,73%	1,05%
Probabilidad	0,48	0,70	0,00	0,00	0,57	0,01

Tabla 4.5: Matriz de correlación portafolios independientes. Software utilizado Eviews.

Con respecto a la matriz de correlaciones entre los factores (Tabla 4.4), en el ordenamiento dependiente, el factor premio por riesgo (RM-RF) solo tiene

correlación positiva con el factor tamaño (SMB), a su vez este último factor se correlaciona positivamente con el factor de rentabilidad (RMW), al igual que el factor valor (HML). El factor de rentabilidad operacional se correlaciona positivamente con el factor de inversión (CMA). Con respecto al periodo sin pandemia, el factor de premio por riesgo obtiene correlación positiva con el factor valor, al igual que el factor de tamaño. El factor valor al igual que el factor inversión se correlaciona positivamente con el factor inversión y finalmente el factor inversión se correlaciona positivamente con el factor de rentabilidad operacional.

Revisando el ordenamiento independiente (Tabla 4.5), el factor de premio por riesgo se correlaciona positivamente con el factor tamaño y el factor valor, en ambos periodos. El factor de tamaño se correlaciona positivamente con el factor valor en el periodo completo y con el factor de rentabilidad en periodo sin pandemia. El factor valor se correlaciona positivamente con el factor de rentabilidad en ambos periodos, agregando el factor de momentum en el período sin pandemia y finalmente el factor de rentabilidad operacional se correlaciona positivamente con el factor de inversión y factor de rentabilidad en ambos períodos.

4.6.1.-Análisis panel size – ratio B/M.

Se analizaron los coeficientes e interceptos de los modelos en estudio, para los cuatro portafolios, de acuerdo con las variables de ordenamiento, en primer lugar, tamaño (SMB) y ratio B/M en segundo orden, para portafolios armados en forma independiente y dependiente, además se revisa la significancia estadística de los coeficientes al 95%.

		Portafolios Independientes				Portafolios Dependientes			
		Low		High		Low		High	
Modelo	Size - B/M	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
CAPM									
PC	Small	0,00	0,01*	0,00	0,01*	-0,01	0,00*	0,00	0,31
PC	Big	0,00	0,00*	0,00	0,03*	0,00	0,04*	0,00	0,12
PSP	Small	0,00	0,03*	0,00	0,02*	-0,01	0,00*	0,00	0,74
PSP	Big	0,00	0,00*	0,00	0,12	0,00	0,01*	0,00	0,51
		RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.
PC	Small	1,11	0,00*	1,12	0,00*	1,19	0,00*	1,17	0,00*

PC	Big	1,06	0,00*	1,04	0,00*	1,05	0,00*	0,99	0,00*
PSP	Small	1,11	0,00*	1,11	0,00*	1,16	0,00*	1,19	0,00*
PSP	Big	1,05	0,00*	1,05	0,00*	1,11	0,00*	0,88	0,00*
Modelo		Low		High		Low		High	
FF3F									
	Size - B/M	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	0,00	0,56	0,00	0,09	-0,01	0,00*	0,00	0,89
PC	Big	0,00	0,00*	0,00	0,03*	0,00	0,07	-0,01	0,00*
PSP	Small	0,00	0,28	0,00	0,00*	0,00	0,01*	0,00	0,85
PSP	Big	0,00	0,00*	0,00	0,02*	0,00	0,09	0,00	0,01*
		RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.
PC	Small	-0,05	0,04*	-0,14	0,00*	1,04	0,00*	1,20	0,00*
PC	Big	0,09	0,00*	0,18	0,00*	1,08	0,00*	1,03	0,00*
PSP	Small	-0,08	0,01*	-0,18	0,00*	0,95	0,00*	1,30	0,00*
PSP	Big	0,12	0,00*	0,22	0,00*	1,11	0,00*	0,94	0,00*
		SMB	Prob.	SMB	Prob.	SMB	Prob.	SMB	Prob.
PC	Small	0,53	0,00*	0,58	0,00*	0,86	0,00*	0,81	0,00*
PC	Big	0,44	0,00*	0,40	0,00*	-0,32	0,00*	-0,13	0,01*
PSP	Small	0,55	0,00*	0,60	0,00*	0,93	0,00*	0,89	0,00*
PSP	Big	0,43	0,00*	0,38	0,00*	-0,27	0,00*	-0,07	0,17
		HML	Prob.	HML	Prob.	HML	Prob.	HML	Prob.
PC	Small	-0,74	0,00*	-0,01	0,80	-0,38	0,00*	0,57	0,00*
PC	Big	-0,28	0,00*	0,99	0,00*	-0,53	0,00*	0,62	0,00*
PSP	Small	-0,69	0,00*	0,02	0,65	-0,49	0,00*	0,71	0,00*
PSP	Big	-0,35	0,00*	0,94	0,00*	-0,45	0,00*	0,51	0,00*
Modelo		Low		High		Low		High	
FC4F									
	Size - B/M	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	0,00	0,05*	0,00	0,01*	-0,01	0,00*	0,00	0,37
PC	Big	0,00	0,07	0,00	0,22	0,00	0,33	-0,01	0,00*
PSP	Small	0,00	0,01*	0,00	0,00*	0,00	0,01*	0,00	0,44
PSP	Big	0,00	0,02*	0,00	0,26	0,00	0,39	0,00	0,01*
		RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.
PC	Small	-0,02	0,45	-0,12	0,00*	1,04	0,00*	1,07	0,00*

PC	Big	0,06	0,01*	0,16	0,00*	1,07	0,00*	1,03	0,00*
PSP	Small	-0,02	0,51	-0,14	0,00*	0,95	0,00*	1,10	0,00*
PSP	Big	0,06	0,03*	0,18	0,00*	1,10	0,00*	0,94	0,00*
		SMB	Prob.	SMB	Prob.	SMB	Prob.	SMB	Prob.
PC	Small	0,52	0,00*	0,57	0,00*	0,86	0,00*	0,67	0,00*
PC	Big	0,46	0,00*	0,41	0,00*	-0,32	0,00*	-0,13	0,01*
PSP	Small	0,53	0,00*	0,58	0,00*	0,92	0,00*	0,73	0,00*
PSP	Big	0,46	0,00*	0,40	0,00*	-0,26	0,00*	-0,07	0,17
		HML	Prob.	HML	Prob.	HML	Prob.	HML	Prob.
PC	Small	-0,73	0,00*	-0,01	0,86	-0,40	0,00*	0,62	0,00*
PC	Big	-0,29	0,00*	0,99	0,00*	-0,39	0,00*	0,60	0,00*
PSP	Small	-0,73	0,00*	-0,01	0,72	-0,48	0,00*	0,68	0,00*
PSP	Big	-0,30	0,00*	0,98	0,00*	-0,33	0,00*	0,52	0,00*
		WML	Prob.	RMW	Prob.	RMW	Prob.	RMW	Prob.
PC	Small	0,22	0,00*	0,13	0,00*	0,02	0,76	-0,28	0,00*
PC	Big	-0,24	0,00*	-0,15	0,00*	-0,26	0,00*	0,05	0,57
PSP	Small	0,23	0,00*	0,16	0,00*	-0,03	0,66	-0,24	0,00*
PSP	Big	-0,23	0,00*	-0,17	0,00*	-0,22	0,00*	-0,01	0,86
Modelo		Low		High		Low		High	
FF5F									
	Size - B/M	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	0,00	0,50	0,00	0,04*	-0,01	0,00*	0,00	0,02*
PC	Big	0,00	0,00*	0,00	0,06	0,00	0,02*	0,00	0,00*
PSP	Small	0,00	0,24	0,00	0,00*	0,00	0,01*	0,00	0,03*
PSP	Big	0,00	0,00*	0,00	0,04	0,00	0,03*	0,00	0,01*
		RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.
PC	Small	-0,06	0,03*	-0,11	0,00*	1,06	0,00*	1,02	0,00*
PC	Big	0,10	0,00*	0,15	0,00*	1,02	0,00*	1,06	0,00*
PSP	Small	-0,09	0,01*	-0,17	0,00*	1,00	0,00*	1,07	0,00*
PSP	Big	0,13	0,00*	0,21	0,00*	1,07	0,00*	0,99	0,00*
		SMB	Prob.	SMB	Prob.	SMB	Prob.	SMB	Prob.
PC	Small	0,54	0,00*	0,57	0,00*	0,79	0,00*	0,66	0,00*
PC	Big	0,44	0,00*	0,41	0,00*	-0,34	0,00*	-0,20	0,00*
PSP	Small	0,55	0,00*	0,59	0,00*	0,86	0,00*	0,69	0,00*
PSP	Big	0,43	0,00*	0,39	0,00*	-0,30	0,00*	-0,14	0,00*

		HML	Prob.	HML	Prob.	HML	Prob.	HML	Prob.
PC	Small	-0,76	0,00*	-0,10	0,07	-0,76	0,00*	0,39	0,00*
PC	Big	-0,25	0,00*	1,08	0,00*	-0,61	0,00*	0,23	0,01*
PSP	Small	-0,70	0,00*	-0,06	0,27	-0,76	0,00*	0,49	0,00*
PSP	Big	-0,35	0,00*	1,01	0,00*	-0,52	0,00*	0,24	0,00*
		RMW	Prob.	RMW	Prob.	RMW	Prob.	RMW	Prob.
PC	Small	-0,03	0,53	0,13	0,01*	0,47	0,00*	-0,01	0,92
PC	Big	0,03	0,55	-0,13	0,01*	0,01	0,83	0,49	0,00*
PSP	Small	-0,02	0,66	0,07	0,10	0,37	0,00*	0,02	0,79
PSP	Big	0,03	0,52	-0,06	0,19	0,04	0,53	0,39	0,00*
		CMA	Prob.	CMA	Prob.	CMA	Prob.	CMA	Prob.
PC	Small	-0,09	0,22	-0,10	0,11	-0,16	0,03*	-0,34	0,00*
PC	Big	0,09	0,17	0,10	0,12	-0,33	0,00*	-0,15	0,05*
PSP	Small	-0,06	0,41	-0,12	0,04*	-0,06	0,38	-0,25	0,00*
PSP	Big	0,04	0,59	0,09	0,14	-0,25	0,00*	-0,06	0,42

Tabla 4.6: Resultados de Panel tamaño (Size), Ratio Book to Market. Software utilizado Eviews.

*significancia estadística P-Value < 0,005

En la tabla 4.6, se puede visualizar que en el modelo CAPM para el ordenamiento dependiente e independiente, los interceptos para los cuatro portafolios son cercanos a cero, lo que muestra concordancia teórica. Sin embargo, seis de ocho portafolios contienen significancia estadística en período completo (PC) y cinco en período sin pandemia (PSP). El factor de premio por riesgo (RM-RF) obtiene significancia estadística en todos los portafolios en ambos períodos.

Para el modelo de Fama French de tres factores, las variables que obtienen mayor significancia estadística son el factor de premio por riesgo y el factor de tamaño (SMB) en ambos períodos y en menor medida el factor valor (HML) en ambos ordenamientos de portafolios y períodos.

En el modelo de cuatro factores, el intercepto obtiene significancia estadística en menos de seis portafolios en ambos períodos, las variables de mayor significancia estadística son el premio por riesgo y el factor tamaño, en menor medida el factor valor y el factor momentum (WML) en los dos períodos.

Finalmente, en el modelo de Fama French de cinco factores, el factor que es más robusto estadísticamente es el factor tamaño, el cual tiene concordancia con la teoría donde las empresas pequeñas obtienen mayor coeficiente que las empresas de mayor tamaño, seguido por el factor de premio por riesgo, y del factor valor,

y en mucho menor medida el factor de rentabilidad operacional (RMW) y de inversión (CMA), en el período completo (PC) y sin pandemia (PSP).

4.6.2.-Análisis panel Size – Rentabilidad Operacional

Se analizarán los coeficientes e interceptos de los modelos en estudio, para los cuatro portafolios, de acuerdo con las variables de ordenamiento, en primer lugar, tamaño (SMB) y en segundo orden por rentabilidad (RMW), para portafolios armados en forma independiente y dependiente, además se revisa la significancia estadística de los coeficientes al 95%.

		Portafolios Independientes				Portafolios Dependientes			
		Weak		Robust		Weak		Robust	
Modelo	Size - Rent. Op.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	-0,01	0,00*	-0,01	0,01*	-0,01	0,02*	-0,01	0,06
PC	Big	0,00	0,00*	0,00	0,01*	0,00	0,06	0,00	0,11
PSP	Small	0,00	0,01*	0,00	0,04*	-0,01	0,04*	0,00	0,14
PSP	Big	0,00	0,01*	0,00	0,04*	0,00	0,02*	0,00	0,49
		RM-RF	Prob.	RM-RF	Prob.	RM- RF	Prob.	RM- RF	Prob.
PC	Small	1,13	0,00*	1,13	0,00*	1,24	0,00*	1,11	0,00*
PC	Big	1,08	0,00*	1,03	0,00*	1,07	0,00*	0,96	0,00*
PSP	Small	1,13	0,00*	1,12	0,00*	1,25	0,00*	1,10	0,00*
PSP	Big	1,08	0,00*	1,02	0,00*	1,11	0,00*	0,88	0,00*
Modelo		Weak		Robust		Weak		Robust	
FF3F	Size - Rent. Op.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	0,00	0,11	0,00	0,45	0,00	0,02*	0,00	0,03*
PC	Big	0,00	0,03*	0,00	0,11	0,00	0,16	-0,01	0,00*
PSP	Small	0,00	0,01*	0,00	0,11	0,00	0,11	0,00	0,07
PSP	Big	0,00	0,02*	0,00	0,09	0,00	0,24	0,00	0,02*
		RM-RF	Prob.	RM-RF	Prob.	RM- RF	Prob.	RM- RF	Prob.
PC	Small	0,00	0,91	-0,24	0,00*	1,13	0,00*	0,98	0,00*

PC	Big	0,23	0,00*	0,03	0,29	1,09	0,00*	1,02	0,00*
PSP	Small	-0,02	0,51	-0,30	0,00*	1,11	0,00*	0,94	0,00*
PSP	Big	0,29	0,00*	0,03	0,41	1,09	0,00*	0,97	0,00*
		SMB	Prob.	SMB	Prob.	SMB	Prob.	SMB	Prob.
PC	Small	0,52	0,00*	0,63	0,00*	0,66	0,00*	0,89	0,00*
PC	Big	0,39	0,00*	0,46	0,00*	-0,24	0,00*	-0,22	0,00*
PSP	Small	0,53	0,00*	0,65	0,00*	0,66	0,00*	1,02	0,00*
PSP	Big	0,36	0,00*	0,46	0,00*	-0,16	0,00*	-0,20	0,00*
		HML	Prob.	HML	Prob.	HML	Prob.	HML	Prob.
PC	Small	-0,58	0,00*	-0,09	0,14	-0,14	0,04*	0,19	0,02*
PC	Big	0,19	0,00*	0,39	0,00*	-0,51	0,00*	0,60	0,00*
PSP	Small	-0,56	0,00*	0,00	0,93	-0,17	0,02*	0,18	0,04*
PSP	Big	0,16	0,04*	0,30	0,00*	-0,47	0,00*	0,54	0,00*
Modelo		Weak		Robust		Weak		Robust	
FC4F									
	Size - Rent. Op.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	0,00	0,01*	0,00	0,15	0,00	0,07	0,00	0,04*
PC	Big	0,00	0,29	0,00	0,30	0,00	0,35	-0,01	0,00*
PSP	Small	0,00	0,00*	0,00	0,01*	0,00	0,30	0,00	0,12
PSP	Big	0,00	0,28	0,00	0,26	0,00	0,49	0,00	0,04*
		RM-RF	Prob.	RM-RF	Prob.	RM- RF	Prob.	RM- RF	Prob.
PC	Small	0,03	0,36	-0,21	0,00*	1,12	0,00*	0,98	0,00*
PC	Big	0,18	0,00*	0,02	0,63	1,08	0,00*	1,02	0,00*
PSP	Small	0,04	0,34	-0,26	0,00*	1,10	0,00*	0,93	0,00*
PSP	Big	0,22	0,00*	0,00	0,98	1,08	0,00*	0,96	0,00*
		SMB	Prob.	SMB	Prob.	SMB	Prob.	SMB	Prob.
PC	Small	0,51	0,00*	0,62	0,00*	0,66	0,00*	0,89	0,00*
PC	Big	0,41	0,00*	0,46	0,00*	-0,24	0,00*	-0,22	0,00*
PSP	Small	0,51	0,00*	0,64	0,00*	0,67	0,00*	1,02	0,00*
PSP	Big	0,40	0,00*	0,47	0,00*	-0,15	0,00*	-0,19	0,00*
		HML	Prob.	HML	Prob.	HML	Prob.	HML	Prob.
PC	Small	-0,57	0,00*	-0,09	0,14	-0,04	0,61	0,22	0,03*
PC	Big	0,19	0,00*	0,39	0,00*	-0,43	0,00*	0,65	0,00*
PSP	Small	-0,60	0,00*	-0,04	0,55	-0,07	0,40	0,22	0,03*

PSP	Big	0,22	0,00*	0,33	0,00*	-0,40	0,00*	0,60	0,00*
		WML	Prob.	RMW	Prob.	RMW	Prob.	RMW	Prob.
PC	Small	0,21	0,00*	0,15	0,00*	-0,19	0,01*	-0,04	0,64
PC	Big	-0,27	0,00*	-0,11	0,02*	-0,15	0,04*	-0,15	0,04*
PSP	Small	0,23	0,00*	0,16	0,00*	-0,18	0,02*	-0,07	0,45
PSP	Big	-0,29	0,00*	-0,11	0,06	-0,13	0,04*	-0,13	0,04*
Modelo		Weak		Robust		Weak		Robust	
FF5F									
	Size - Rent. Op.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	0,00	0,16	0,00	0,11	-0,01	0,00*	0,00	0,02*
PC	Big	0,00	0,03*	0,00	0,03*	0,00	0,02*	0,00	0,00*
PSP	Small	0,00	0,02*	0,00	0,01*	0,00	0,02*	0,00	0,03*
PSP	Big	0,00	0,03*	0,00	0,00*	0,00	0,03*	0,00	0,03*
		RM-RF	Prob.	RM-RF	Prob.	RM- RF	Prob.	RM- RF	Prob.
PC	Small	-0,10	0,00*	-0,13	0,00*	1,08	0,00*	0,99	0,00*
PC	Big	0,11	0,00*	0,14	0,00*	1,00	0,00*	1,08	0,00*
PSP	Small	-0,14	0,00*	-0,19	0,00*	1,06	0,00*	1,00	0,00*
PSP	Big	0,14	0,00*	0,19	0,00*	1,01	0,00*	1,06	0,00*
		SMB	Prob.	SMB	Prob.	SMB	Prob.	SMB	Prob.
PC	Small	0,56	0,00*	0,58	0,00*	0,70	0,00*	0,76	0,00*
PC	Big	0,44	0,00*	0,42	0,00*	-0,25	0,00*	-0,30	0,00*
PSP	Small	0,58	0,00*	0,61	0,00*	0,73	0,00*	0,84	0,00*
PSP	Big	0,42	0,00*	0,40	0,00*	-0,17	0,00*	-0,28	0,00*
		HML	Prob.	HML	Prob.	HML	Prob.	HML	Prob.
PC	Small	-0,43	0,00*	-0,33	0,00*	0,09	0,31	-0,56	0,00*
PC	Big	0,39	0,00*	0,30	0,00*	-0,53	0,00*	0,13	0,16
PSP	Small	-0,42	0,00*	-0,20	0,00*	0,12	0,14	-0,50	0,00*
PSP	Big	0,37	0,00*	0,15	0,02*	-0,46	0,00*	0,17	0,06
		RMW	Prob.	RMW	Prob.	RMW	Prob.	RMW	Prob.
PC	Small	-0,44	0,00*	0,50	0,00*	-0,34	0,00*	0,91	0,00*
PC	Big	-0,56	0,00*	0,50	0,00*	-0,12	0,07	0,64	0,00*
PSP	Small	-0,42	0,00*	0,42	0,00*	-0,42	0,00*	0,91	0,00*
PSP	Big	-0,58	0,00*	0,58	0,00*	-0,11	0,05*	0,56	0,00*
		CMA	Prob.	CMA	Prob.	CMA	Prob.	CMA	Prob.

PC	Small	0,00	0,95	-0,15	0,05*	-0,06	0,00*	-0,44	0,00*
PC	Big	0,02	0,80	0,18	0,02*	-0,42	0,57	-0,04	0,57
PSP	Small	-0,03	0,70	-0,12	0,11	0,04	0,00*	-0,36	0,00*
PSP	Big	0,02	0,81	0,10	0,14	-0,34	0,52	0,05	0,52

Tabla 4.7: Resultados panel tamaño (Size), rentabilidad operacional. Software utilizado Eviews.

*significancia estadística P-Value < 0,005

De acuerdo con la tabla 4.7, revisando el resultado del modelo CAPM, el factor de premio por riesgo obtiene significancia estadística en todos los portafolios, en ambos ordenamientos y en periodo sin pandemia (PSP) y período completo (PC). Con respecto al modelo de tres factores, el intercepto alfa en todos los portafolios es cercano a cero, pero solo tres tienen significancia estadística; El factor que obtiene mejor significancia estadística en todos los portafolios, es el factor tamaño (SMB), seguido del factor valor (HML), con respecto al factor de premio por riesgo (RM-RF), obtiene bajos coeficientes y poca significancia estadística en los portafolios. Revisando el modelo de cuatro factores, la variable que obtiene en todos los portafolios significancia estadística es el de tamaño, seguido con el factor de momentum (WML) y el factor valor, finalmente el premio por riesgo.

Con respecto al modelo de cinco factores, se obtiene que el factor con mayor significancia estadística es el factor de tamaño, al igual que el factor de premio por riesgo. El intercepto alfa obtiene significancia estadística en solo seis portafolios. En el caso del factor de valor en portafolios independientes, todos logran significancia estadística, obteniendo un patrón similar al estudio original de Fama French, donde las empresas grandes en capitalización bursátil obtienen coeficientes mayores y positivos y las empresas pequeñas valores menores, seguido del factor de rentabilidad operacional (RMW), el cual también se comporta de acuerdo con la teoría que indica que los portafolios donde convergen las empresas de menor tamaño bursátil y rentabilidad débil obtienen menores coeficientes. Se aprecia también que los portafolios de empresas de gran tamaño bursátil y rentabilidad débil obtienen menores coeficientes, tanto en periodo con o sin pandemia, finalmente el factor de inversión (CMA) es el que menos obtiene significancia estadística en los portafolios en ambos periodos.

4.6.3.-Análisis panel Size – inversiones.

Se analizarán los coeficientes e interceptos de los modelos en estudio, para los cuatro portafolios, de acuerdo con las variables de ordenamiento, en primer

lugar, tamaño (SMB) y segundo orden de acuerdo con el factor de inversión (CMA), para portafolios armados en forma independiente y dependiente, además se revisa la significancia estadística de los coeficientes al 95%.

		Portafolios Independientes				Portafolios Dependientes			
		Conservative		Agresive		Conservative		Agresive	
Modelo	Size - Inv	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
CAPM									
PC	Small	0,00	0,01*	-0,01	0,00*	-0,01	0,00*	0,00	0,57
PC	Big	-0,01	0,00*	0,00	0,07	0,00	0,20	-0,01	0,02*
PSP	Small	0,00	0,03*	0,00	0,01*	-0,01	0,00*	0,00	0,93
PSP	Big	0,00	0,00*	0,00	0,27	0,00	0,35	0,00	0,02*
		RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.
PC	Small	1,09	0,00*	1,17	0,00*	1,14	0,00*	1,22	0,00*
PC	Big	1,04	0,00*	1,07	0,00*	0,89	0,00*	1,17	0,00*
PSP	Small	1,09	0,00*	1,16	0,00*	1,11	0,00*	1,26	0,00*
PSP	Big	1,03	0,00*	1,07	0,00*	0,89	0,00*	1,13	0,00*
Modelo		Conservative		Agresive		Conservative		Agresive	
FF3F									
	Size - Inv	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	0,00	0,75	0,00	0,03*	-0,01	0,00*	0,00	0,57
PC	Big	0,00	0,00*	0,00	0,85	0,00	0,09	-0,01	0,01*
PSP	Small	0,00	0,11	0,00	0,00*	-0,01	0,00*	0,00	0,70
PSP	Big	0,00	0,00*	0,00	0,79	0,00	0,07	0,00	0,08
		RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.
PC	Small	-0,12	0,00*	-0,12	0,00*	1,01	0,00*	1,11	0,00*
PC	Big	0,11	0,00*	0,16	0,00*	0,93	0,00*	1,20	0,00*
PSP	Small	-0,20	0,00*	-0,14	0,00*	0,92	0,00*	1,15	0,00*
PSP	Big	0,17	0,00*	0,16	0,00*	0,95	0,00*	1,12	0,00*
		SMB	Prob.	SMB	Prob.	SMB	Prob.	SMB	Prob.
PC	Small	0,56	0,00*	0,60	0,00*	0,77	0,00*	0,77	0,00*
PC	Big	0,43	0,00*	0,42	0,00*	-0,29	0,00*	-0,17	0,01*
PSP	Small	0,59	0,00*	0,60	0,00*	0,83	0,00*	0,82	0,00*
PSP	Big	0,40	0,00*	0,42	0,00*	-0,27	0,00*	-0,06	0,28
		HML	Prob.	HML	Prob.	HML	Prob.	HML	Prob.
PC	Small	-0,50	0,00*	-0,17	0,00*	-0,21	0,00*	0,27	0,00*

PC	Big	0,03	0,59	0,56	0,00*	0,02	0,76	-0,01	0,92
PSP	Small	-0,36	0,00*	-0,20	0,00*	-0,34	0,00*	0,38	0,00*
PSP	Big	-0,11	0,08	0,59	0,00*	0,17	0,02*	-0,19	0,01*
Modelo		Conservative		Agresive		Conservative		Agresive	
FC4F									
	Size - Inv	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	0,00	0,00*	0,00	0,06	-0,01	0,00*	0,00	0,37
PC	Big	0,00	0,01*	0,00	0,57	0,00	0,09	0,00	0,06
PSP	Small	0,00	0,00*	0,00	0,00*	0,00	0,01*	0,00	0,37
PSP	Big	0,00	0,00*	0,00	0,66	0,00	0,10	0,00	0,28
		RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.
PC	Small	-0,06	0,01*	-0,13	0,00*	1,00	0,00*	1,11	0,00*
PC	Big	0,03	0,17	0,18	0,00*	0,93	0,00*	1,19	0,00*
PSP	Small	-0,10	0,00*	-0,13	0,00*	0,90	0,00*	1,16	0,00*
PSP	Big	0,03	0,21	0,19	0,00*	0,95	0,00*	1,11	0,00*
		SMB	Prob.	SMB	Prob.	SMB	Prob.	SMB	Prob.
PC	Small	0,53	0,00*	0,60	0,00*	0,77	0,00*	0,78	0,00*
PC	Big	0,46	0,58	0,41	0,00*	-0,29	0,00*	-0,17	0,01*
PSP	Small	0,55	0,00*	0,59	0,00*	0,85	0,00*	0,81	0,00*
PSP	Big	0,46	0,00*	0,41	0,00*	-0,27	0,00*	-0,05	0,36
		HML	Prob.	HML	Prob.	HML	Prob.	HML	Prob.
PC	Small	-0,49	0,00*	-0,17	0,00*	-0,03	0,72	0,20	0,02*
PC	Big	0,02	0,58	0,56	0,00*	0,01	0,90	0,14	0,17
PSP	Small	-0,43	0,00*	-0,21	0,00*	-0,13	0,05*	0,29	0,00*
PSP	Big	-0,01	0,81	0,56	0,00*	0,19	0,03*	-0,07	0,42
		WML	Prob.	RMW	Prob.	RMW	Prob.	RMW	Prob.
PC	Small	0,41	0,00*	-0,05	0,28	-0,34	0,00*	0,13	0,12
PC	Big	-0,52	0,00*	0,14	0,00*	0,02	0,79	-0,28	0,00*
PSP	Small	0,35	0,00*	0,04	0,42	-0,41	0,00*	0,18	0,03*
PSP	Big	-0,52	0,00*	0,12	0,01*	-0,04	0,65	-0,23	0,00*
Modelo		Conservative		Agresive		Conservative		Agresive	
FF5F									
	Size - Inv	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	0,00	0,83	0,00	0,00*	-0,01	0,00*	0,00	0,25
PC	Big	0,00	0,00*	0,00	0,68	0,00	0,00*	-0,01	0,00*

PSP	Small	0,00	0,37	0,00	0,00*	0,00	0,00*	0,00	0,24
PSP	Big	0,00	0,00*	0,00	0,37	0,00	0,00*	0,00	0,00*
		RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.
PC	Small	-0,12	0,00*	-0,11	0,00*	1,06	0,00*	1,01	0,00*
PC	Big	0,13	0,00*	0,12	0,00*	1,01	0,00*	1,06	0,00*
PSP	Small	-0,19	0,00*	-0,14	0,00*	1,01	0,00*	1,06	0,00*
PSP	Big	0,19	0,00*	0,14	0,00*	1,05	0,00*	1,01	0,00*
		SMB	Prob.	SMB	Prob.	SMB	Prob.	SMB	Prob.
PC	Small	0,56	0,00*	0,58	0,00*	0,73	0,00*	0,72	0,00*
PC	Big	0,44	0,00*	0,42	0,00*	-0,28	0,00*	-0,27	0,00*
PSP	Small	0,60	0,00*	0,59	0,00*	0,83	0,00*	0,73	0,00*
PSP	Big	0,40	0,00*	0,42	0,00*	-0,27	0,00*	-0,17	0,00*
		HML	Prob.	HML	Prob.	HML	Prob.	HML	Prob.
PC	Small	-0,33	0,00*	-0,42	0,00*	-0,44	0,00*	0,03	0,78
PC	Big	0,31	0,00*	0,39	0,00*	-0,01	0,95	-0,47	0,00*
PSP	Small	-0,20	0,00*	-0,41	0,00*	-0,44	0,00*	0,13	0,12
PSP	Big	0,16	0,02*	0,37	0,00*	0,10	0,22	-0,47	0,00*
		RMW	Prob.	RMW	Prob.	RMW	Prob.	RMW	Prob.
PC	Small	-0,02	0,74	0,10	0,08	0,34	0,00*	0,15	0,04*
PC	Big	0,02	0,78	-0,10	0,05*	0,15	0,29	0,34	0,00*
PSP	Small	-0,03	0,63	0,04	0,47	0,21	0,00*	0,20	0,00*
PSP	Big	0,02	0,68	-0,04	0,41	0,20	0,00*	0,21	0,00*
		CMA	Prob.	CMA	Prob.	CMA	Prob.	CMA	Prob.
PC	Small	0,37	0,00*	-0,51	0,00*	0,09	0,29	-0,61	0,00*
PC	Big	0,64	0,00*	-0,47	0,00*	0,36	0,00*	-0,94	0,00*
PSP	Small	0,34	0,00*	-0,47	0,00*	0,27	0,00*	-0,62	0,00*
PSP	Big	0,65	0,00*	-0,55	0,00*	0,36	0,00*	-0,75	0,00*

Tabla 4.8: Resultados panel tamaño (Size), nivel de inversión. Software utilizado Eviews.

*significancia estadística P-Value < 0,005

Según la tabla 4.8, se puede apreciar que el modelo CAPM sólo cinco portafolios presentan significancia estadística para el intercepto alfa en ambos períodos, para el factor de mercado (RM-RF) presenta significancia estadística en todos los portafolios, donde los portafolios de empresas pequeñas en términos de capital bursátil obtienen mayores coeficientes en ambos períodos. Revisando el modelo de tres factores, las variables que obtienen significancia estadística en la mayoría de los portafolios son el premio por riesgo y el factor de tamaño (SMB). En menos

portafolios obtienen significancia el intercepto alfa y el factor valor (HML) en ambos periodos analizados. Con respecto al modelo de cuatro factores, los factores que obtienen en más portafolios significancia estadística son el premio por riesgo y tamaño, seguido por el factor momentum (WML), en menor medida obtiene significancia estadística el factor valor, tanto en periodos con pandemia (PC) y sin pandemia (PSP), finalmente revisando la significancia estadística de los coeficientes del modelo de cinco factores, la variable que obtienen significancia estadística en todos los portafolios es el premio por riesgos, seguido del factor de tamaño y el factor de inversión (CMA), en menor medida obtienen significancia estadística en los portafolios los factores de valor y el factor de rentabilidad operacional (RMW)

4.6.4.-Análisis panel Size – Momentum del retorno

Se analizarán los coeficientes e interceptos de los modelos en estudio, para los cuatro portafolios, de acuerdo con las variables de ordenamiento, en primer lugar, tamaño (SMB) y en segundo orden el factor momentum (WML), para portafolios armados en forma independiente y dependiente, además se revisa la significancia estadística de los coeficientes al 95%.

		Portafolios Independientes				Portafolios Dependientes			
		Winner		Looser		Winner		Looser	
Modelo	Size - Mom.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	0,00	0,03*	-0,01	0,00*	0,00	1,00	-0,01	0,00*
PC	Big	0,00	0,05*	-0,01	0,00*	0,00	0,25	-0,01	0,02*
PSP	Small	0,00	0,07	0,00	0,00*	0,00	0,62	-0,01	0,00*
PSP	Big	0,00	0,24	-0,01	0,00*	0,00	0,77	0,00	0,02*
		RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.
PC	Small	1,12	0,00*	1,14	0,00*	1,10	0,00*	1,25	0,00*
PC	Big	1,05	0,00*	1,08	0,00*	1,05	0,00*	0,99	0,00*
PSP	Small	1,11	0,00*	1,13	0,00*	1,13	0,00*	1,22	0,00*
PSP	Big	1,05	0,00*	1,07	0,00*	0,93	0,00*	1,06	0,00*
Modelo		Winner		Looser		Winner		Looser	
FF3F									
	Size - Mom.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	0,00	0,46	0,00	0,00*	0,00	0,77	-0,01	0,00*

PC	Big	0,00	0,99	0,00	0,00*	0,00	0,03*	0,00	0,02*
PSP	Small	0,00	0,92	0,00	0,00*	0,00	0,51	-0,01	0,00*
PSP	Big	0,00	0,71	0,00	0,00*	0,00	0,12	0,00	0,03*
		RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.
PC	Small	-0,21	0,00*	-0,05	0,00*	1,00	0,00*	1,11	0,00*
PC	Big	0,06	0,03*	0,22	0,00*	1,09	0,00*	1,02	0,00*
PSP	Small	-0,34	0,00*	-0,04	0,07	1,02	0,00*	1,04	0,00*
PSP	Big	0,06	0,04*	0,29	0,00*	0,97	0,00*	1,08	0,00*
		SMB	Prob.	SMB	Prob.	SMB	Prob.	SMB	Prob.
PC	Small	0,61	0,00*	0,55	0,00*	0,72	0,00*	0,82	0,00*
PC	Big	0,45	0,00*	0,40	0,00*	-0,19	0,00*	-0,26	0,00*
PSP	Small	0,67	0,00*	0,54	0,00*	0,77	0,00*	0,88	0,00*
PSP	Big	0,46	0,00*	0,36	0,00*	-0,07	0,07	-0,26	0,00*
		HML	Prob.	HML	Prob.	HML	Prob.	HML	Prob.
PC	Small	-0,58	0,00*	-0,14	0,00*	0,22	0,00*	-0,16	0,03*
PC	Big	0,49	0,00*	0,09	0,29	0,37	0,00*	-0,31	0,00*
PSP	Small	-0,42	0,00*	-0,16	0,00*	0,29	0,00*	-0,26	0,00*
PSP	Big	0,54	0,00*	-0,11	0,20	0,27	0,00*	-0,24	0,00*
Modelo		Winner		Looser		Winner		Looser	
FC4F									
	Size - Mom.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	0,00	0,01*	0,00	0,00*	0,00	0,07	-0,01	0,00*
PC	Big	0,00	0,07	0,00	0,01*	-0,01	0,00*	0,00	0,36
PSP	Small	0,00	0,00*	0,00	0,00*	0,00	0,30	0,00	0,00*
PSP	Big	0,00	0,12	0,00	0,00*	0,00	0,00*	0,00	0,44
		RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.
PC	Small	0,03	0,36	-0,08	0,00*	1,12	0,00*	1,10	0,00*
PC	Big	0,11	0,00*	0,09	0,00*	1,10	0,00*	1,01	0,00*
PSP	Small	0,04	0,34	-0,08	0,00*	1,10	0,00*	1,00	0,00*
PSP	Big	0,14	0,00*	0,06	0,00*	1,00	0,00*	1,05	0,00*
		SMB	Prob.	SMB	Prob.	SMB	Prob.	SMB	Prob.
PC	Small	0,51	0,00*	0,56	0,00*	0,66	0,00*	0,81	0,00*
PC	Big	0,43	0,00*	0,45	0,00*	-0,19	0,00*	-0,27	0,00*
PSP	Small	0,51	0,00*	0,56	0,00*	0,67	0,00*	0,91	0,00*
PSP	Big	0,42	0,00*	0,46	0,00*	-0,09	0,01*	-0,24	0,00*

		HML	Prob.	HML	Prob.	HML	Prob.	HML	Prob.
PC	Small	-0,57	0,00*	-0,15	0,00*	-0,04	0,61	0,15	0,04*
PC	Big	0,49	0,00*	0,07	0,05*	0,15	0,04*	0,00	1,00
PSP	Small	-0,60	0,00*	-0,13	0,00*	-0,07	0,40	0,09	0,09
PSP	Big	0,49	0,00*	0,05	0,15	0,10	0,08	0,04	0,60
		WML	Prob.	RMW	Prob.	RMW	Prob.	RMW	Prob.
PC	Small	0,21	0,00*	-0,19	0,00*	-0,19	0,01*	-0,59	0,00*
PC	Big	0,30	0,00*	-0,85	0,00*	0,42	0,00*	-0,59	0,00*
PSP	Small	0,23	0,00*	-0,18	0,00*	-0,18	0,02*	-0,67	0,00*
PSP	Big	0,29	0,00*	-0,85	0,00*	0,33	0,00*	-0,53	0,00*
Modelo		Winner		Looser		Winner		Looser	
FF5F									
	Size - Mom.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.	Alfa	Prob.
PC	Small	0,00	0,50	0,00	0,00*	0,00	0,77	-0,01	0,00*
PC	Big	0,00	0,68	0,00	0,00*	0,00	0,04*	0,00	0,01*
PSP	Small	0,00	0,89	0,00	0,00*	0,00	0,63	-0,01	0,00*
PSP	Big	0,00	0,57	0,00	0,00*	0,00	0,16	0,00	0,02*
		RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.	RM-RF	Prob.
PC	Small	-0,19	0,00*	-0,06	0,00*	0,94	0,00*	1,13	0,00*
PC	Big	0,06	0,05*	0,21	0,00*	1,10	0,00*	0,98	0,00*
PSP	Small	-0,33	0,00*	-0,04	0,04*	0,97	0,00*	1,08	0,00*
PSP	Big	0,07	0,02*	0,27	0,00*	0,99	0,00*	1,07	0,00*
		SMB	Prob.	SMB	Prob.	SMB	Prob.	SMB	Prob.
PC	Small	0,60	0,00*	0,55	0,00*	0,63	0,00*	0,81	0,00*
PC	Big	0,45	0,00*	0,42	0,00*	-0,23	0,00*	-0,32	0,00*
PSP	Small	0,67	0,00*	0,54	0,00*	0,65	0,00*	0,90	0,00*
PSP	Big	0,44	0,00*	0,38	0,00*	-0,10	0,02*	-0,33	0,00*
		HML	Prob.	HML	Prob.	HML	Prob.	HML	Prob.
PC	Small	-0,61	0,00*	-0,20	0,00*	-0,20	0,03*	-0,23	0,02*
PC	Big	0,36	0,00*	0,40	0,00*	0,18	0,06	-0,57	0,00*
PSP	Small	-0,44	0,00*	-0,21	0,00*	-0,12	0,20	-0,21	0,02*
PSP	Big	0,35	0,00*	0,22	0,04*	0,18	0,01*	-0,47	0,00*
		RMW	Prob.	RMW	Prob.	RMW	Prob.	RMW	Prob.
PC	Small	0,12	0,21	-0,02	0,64	0,41	0,00*	0,11	0,19
PC	Big	0,01	0,84	-0,12	0,17	0,24	0,00*	0,24	0,00*

PSP	Small	0,04	0,65	-0,02	0,59	0,45	0,00*	-0,01	0,88
PSP	Big	0,08	0,11	-0,14	0,09	0,13	0,02*	0,27	0,00*
		CMA	Prob.	CMA	Prob.	CMA	Prob.	CMA	Prob.
PC	Small	0,02	0,86	-0,15	0,00*	-0,56	0,00*	0,03	0,70
PC	Big	-0,29	0,00*	0,61	0,00*	-0,10	0,23	-0,38	0,00*
PSP	Small	-0,01	0,94	-0,13	0,01*	-0,58	0,00*	0,23	0,00*
PSP	Big	-0,39	0,00*	0,66	0,00*	-0,02	0,71	-0,28	0,00*

Tabla 4.9: Resultados panel tamaño (Size), rentabilidad operacional. Software utilizado Eviews.

*significancia estadística P-Value < 0,005

En la tabla 4.9, se pueden visualizar los coeficientes obtenidos por los modelos, donde el modelo CAPM, solo seis portafolios presentan significancia estadística para el intercepto alfa en el período completo y sólo cuatro en período sin pandemia, para el factor de mercado (RM-RF), presenta significancia estadística en todos los portafolios, pero no existe consistencia con la teoría, porque los portafolios de empresas grandes en términos de capital bursátil obtienen menores coeficientes. Con respecto al modelo de tres factores, solo cinco portafolios obtienen significancia estadística en el intercepto y cinco en periodo sin pandemia, la variable de premio por riesgo, obtiene significancia en todos los portafolios en periodo completo y en siete en periodo con pandemia al igual que el factor de tamaño (SMB), finalmente el factor valor (HML) solo siete portafolios tienen significancia estadística, donde los portafolios de empresas grandes y ganadoras en retornos obtienen mayores retornos que los portafolios perdedores en retorno. Con respecto al modelo de cuatro factores, el intercepto solo obtiene significancia en cinco portafolios en periodo completo y cuatro en período sin pandemia, el factor tamaño y el factor momentum (WML) obtienen significancia estadística en todos los portafolios en ambos periodos, en menor media obtiene significancia el factor premio por riesgo y factor valor. Finalmente, revisando el modelo de cinco factores, los factores que tienen significancia en todos los portafolios y ambos periodos son el premio por riesgo, tamaño, y en menor medida obtienen significancia estadística, el factor de inversión (CMA), valor, y el de rentabilidad operacional (RMW) es el que obtiene menor significancia estadística en ambos períodos.

4.6.5.-Análisis del rendimiento de los modelos

	GRS	P-Value	$A \alpha_i $	$A \left \frac{\hat{\alpha}_i^2}{\hat{\mu}_i^2} \right $	Media R ² Adj.
Panel Ratio Size - B/M – Período Completo					
CAPM	3,32	0,01200	0,00400	0,00800	0,87
FF 3 Factores	1,11	0,35500*	0,00000**	0,00000***	0,99****
FC 4 Factores	0,71	0,58900*	0,00010	0,00000***	0,99****
FF 5 Factores	0,75	0,56100*	0,00000**	0,00000***	0,99****
Panel Ratio Size - B/M – Sin Período de Pandemia					
CAPM	2,62	0,03719	0,00151	0,00151	0,87
FF 3 Factores	1,68	0,15872*	0,00028	0,00020	0,99****
FC 4 Factores	1,41	0,23244*	0,00023**	0,00014***	0,99****
FF 5 Factores	1,19	0,31957*	0,00037	0,00034	0,99****
Panel Size – Rentabilidad. – Período Completo					
CAPM	3,02	0,01949	0,00466	0,01364	0,86
FF 3 Factores	1,56	0,18602*	0,00036	0,00022	0,98
FC 4 Factores	0,81	0,52325*	0,00029	0,00015	0,98
FF 5 Factores	1,00	0,40827*	0,00025**	0,00013***	0,99****
Panel Size – Rentabilidad. – Sin Período De Pandemia					
CAPM	2,62	0,03734	0,00383	0,00943	0,86
FF 3 Factores	2,36	0,05633	0,00044	0,00032	0,98
FC 4 Factores	1,60	0,17715*	0,00043	0,00032	0,98
FF 5 Factores	1,54	0,19464*	0,00021**	0,00009***	0,99****
Panel Size – Inversión – Período Completo					
CAPM	4,30	0,00245	0,00472	0,01413	0,87
FF 3 Factores	2,12	0,07990	0,00082	0,00129	0,99****
FC 4 Factores	0,59	0,67196*	0,00023**	0,00012***	0,99****
FF 5 Factores	1,67	0,16031*	0,00082	0,00144	0,99****
Panel Size – Inversión – Sin Período De Pandemia					
CAPM	4,19	0,00302	0,00391	0,00998	0,86
FF 3 Factores	3,18	0,01540	0,00084	0,00145	0,99****
FC 4 Factores	1,31	0,26850*	0,00034**	0,00026***	0,99****
FF 5 Factores	2,31	0,06072	0,00079	0,00147	0,99****
Panel Size – Momentum – Período Completo					
CAPM	5,47	0,00036	0,00485	0,01449	0,86
FF 3 Factores	5,78	0,00022	0,00452	0,01095	0,84

FC 4 Factores	1,95	0,10477*	0,00015**	0,00006***	0,99****
FF 5 Factores	3,99	0,00407	0,00121	0,00252	0,98
Panel Size – Momentum – Sin Período De Pandemia					
CAPM	6,35	0,00010	0,00405	0,01042	0,86
FF 3 Factores	6,35	0,00010	0,00156	0,00437	0,98
FC 4 Factores	2,41	0,05174	0,00029**	0,00023***	0,99****
FF 5 Factores	4,98	0,00086	0,00129	0,00309	0,98

Tabla 4.10: Resultados de la aplicación del estadístico GRS a Portafolios Independientes, obtenidos con Software Stata.

*significancia estadística P-Value > 10% rechaza hipótesis nula, ** Menor valor absoluto de intercepto (más cercano a cero), *** Menor coeficiente indica el mejor desempeño del modelo de los datos estudiado, **** Mayor R² coeficiente de determinación.

	GRS	P-Value	$A \alpha_i $	$A \left \frac{\hat{\alpha}_i^2}{\hat{\mu}_i^2} \right $	Media R ² Adj.
Panel Ratio Size - B/M – Período Completo					
CAPM	4,04	0,00374	0,00478	0,00967	0,75
FF 3 Factores	3,61	0,00746	0,00440	0,01153	0,87
FC 4 Factores	2,72	0,03137	0,00380**	0,00853***	0,87
FF 5 Factores	3,86	0,00503	0,00426	0,01184	0,89****
Panel Ratio Size - B/M – Sin Período de Pandemia					
CAPM	4,63	0,00149	0,00387	0,00669	0,75
FF 3 Factores	2,58	0,03997	0,00340	0,00774	0,89
FC 4 Factores	1,57	0,18661*	0,00270**	0,00485***	0,89
FF 5 Factores	2,65	0,03544	0,00333	0,00810	0,91****
Panel Size – Rentabilidad. – Período Completo					
CAPM	3,07	0,01802	0,00489	0,00968	0,72
FF 3 Factores	3,47	0,00941	0,00447	0,01054	0,84
FC 4 Factores	2,66	0,03432	0,00388**	0,00778***	0,84
FF 5 Factores	3,59	0,00776	0,00426	0,01175	0,89****
Panel Size – Rentabilidad. – Sin Período De Pandemia					
CAPM	2,89	0,02422	0,00400	0,00658	0,71
FF 3 Factores	2,50	0,04504	0,00346	0,00646	0,84
FC 4 Factores	1,54	0,19354*	0,00277**	0,00405***	0,84
FF 5 Factores	2,64	0,03629	0,00333	0,00769	0,90****
Panel Size – Inversión – Período Completo					
CAPM	5,16	0,00060	0,00483	0,00981	0,75
FF 3 Factores	4,27	0,00258	0,00435	0,00987	0,83
FC 4 Factores	2,88	0,02442	0,00375**	0,00730***	0,84

FF 5 Factores	3,87	0,00494	0,00427	0,01111	0,88****
Panel Size – Inversión – Sin Período De Pandemia					
CAPM	5,33	0,00048	0,00396	0,00685	0,74
FF 3 Factores	3,20	0,01498	0,00333	0,00637	0,85
FC 4 Factores	1,64	0,16717*	0,00266**	0,00410***	0,86
FF 5 Factores	2,85	0,02601	0,00334	0,00781	0,90****
Panel Size – Momemtum – Período Completo					
CAPM	6,80	0,00004	0,00468	0,00928	0,75
FF 3 Factores	5,78	0,00022	0,00452	0,01095	0,84
FC 4 Factores	3,49	0,00909	0,00380**	0,00853***	0,87****
FF 5 Factores	5,39	0,00042	0,00437	0,01073	0,86
Panel Size – Momemtum – Sin Período De Pandemia					
CAPM	6,82	0,00046	0,00431	0,00827	0,75
FF 3 Factores	4,69	0,00136	0,00367	0,00781	0,86
FC 4 Factores	2,47	0,04750	0,00270**	0,00494***	0,90****
FF 5 Factores	4,25	0,00276	0,00342	0,00720	0,87

Tabla 4.11 Resultados de la aplicación del estadístico GRS a Portafolios dependientes, obtenidos con Software Stata.

*significancia estadística P-Value > 10%, rechaza hipótesis nula ** Menor valor absoluto de intercepto (más cercano a cero), *** Menor coeficiente indica el mejor desempeño del modelo de los datos estudiados, **** Mayor R² coeficiente de determinación.

En las tablas 4.10 y 4.11, se muestran los resultados de la prueba GRS para evaluar el desempeño de los modelos sometidos a análisis, donde se aprecia en ambos portafolios sometidos a prueba, es que el p-value disminuye con mayores estadísticos GRS obtenidos. En la primera columna se muestra el estadístico GRS, donde la hipótesis nula de la prueba indica que los interceptos son iguales a cero, por lo tanto, cuan menor es el estadístico, mayor será el p-value asociado, cuando este es menor a 10% se rechaza la hipótesis nula, es decir que todos los interceptos sean iguales a cero.

Revisando que modelos obtiene menor promedio de intercepto en el ordenamiento de portafolios independientes, se puede apreciar que en los portafolios independientes, el modelo Fama Cahart de cuatro factores es el que logra mejor desempeño según el estadístico GRS, también este modelo obtiene el menor intercepto absoluto ($A|\alpha_i|$) en portafolios ordenados por el factor de inversión y el factor momentum, y en cuanto al coeficiente ($A|\bar{\alpha}_i^2/\bar{\mu}_i^2|$), que indica que cuando sea menor el coeficiente mejor será el desempeño del modelo, también para los portafolios ordenados por el factor inversión y momentum, el modelo de Fama Cahart de cuatro factores obtiene el menor coeficiente. Los

portafolios ordenados por el factor valor (HML), el mejor rendimiento lo obtienen tres modelos, Fama French de tres factores, Fama Cahart de cuatro factores y de Fama French de cinco factores.

Con respecto al estadístico coeficiente de determinación (R^2) en ordenamiento independiente, el modelo de Fama Cahart obtiene el mayor coeficiente de determinación en el ordenamiento del factor de inversión y momentum, con respecto al ordenamiento del factor valor, obtienen tres modelos el mayor coeficiente de determinación, de tres factores, cuatro factores y cinco factores.

Al analizar los portafolios ordenados de forma dependientes, el menor estadístico GRS lo obtiene también el modelo de Fama Cahart de cuatro factores. Sin embargo, en este caso ninguno obtiene significancia estadística, pero en el período sin pandemia, si lo obtienen tres ordenamientos, el menor intercepto absoluto ($A|\alpha_i|$), también lo obtiene en todos los ordenamientos, lo obtiene el modelo modificado por Cahart, al igual que el coeficiente ($A|\bar{\alpha}_i^2/\bar{\mu}_i^2|$).

Revisando el coeficiente de determinación R^2 , en ordenamiento dependiente, solo en portafolios del factor momentum obtiene el mayor coeficiente el modelo de Fama Cahart de cuatro factores, en el demás ordenamiento lo obtiene el modelo de Fama French de cinco factores, como también en período sin pandemia,

Finalmente, en cuanto a desempeño de los modelos se obtiene que, en portafolios obtenidos por ordenamiento independiente, el modelo de mejor desempeño es el modelo de Fama Cahart de cuatro factores y modelo de Fama French de cinco factores y en ordenamiento dependiente obtiene mejor desempeño el modelo de Fama Cahart de cuatro factores.

4.7.-Conclusión del capítulo

El análisis obtiene que las variables probadas en portafolios ordenados en forma independiente y dependiente aplicados en los cuatro modelos, el factor de premio por riesgo (RM-RF) y de tamaño (SMB), en la mayoría los portafolios y modelos muestran significancia estadística para el mercado, donde sobresale el factor de tamaño para ambos períodos de estudio, seguido del factor de premio por riesgo. Además, los factores de riesgo factor valor (HML) y Momemtum (WML) también sobresalen en los portafolios, pero con menos significancia estadística en los portafolios analizados; y finalmente los factores que obtienen menos significancia estadística en los portafolios, son los de rentabilidad operacional (RMW), y el factor de inversión (CMA).

En la revisión del modelo de mejor rendimiento por medio de la prueba estadística GRS, se obtiene como conclusión que en ambos ordenamientos el modelo de mayor desempeño es el modelo de Fama Cahart de cuatro factores, donde además del factor de premio de mercado (RM-RF), se compone de los factores de riesgo de tamaño (SMB), valor (HML) y momentum (WML). Esto sugiere que los factores de rentabilidad operacional y de inversión no tienen mayor incidencia en el mercado de valores de Chile en el periodo completo analizado, sin embargo, sacando el período de pandemia, el modelo de cinco factores también tiene mejor desempeño en ordenamiento independiente. Un estudio realizado en el mercado bursátil de Brasil entre 2002 y 2013, somete a análisis el modelo de un factor, de tres factores y de cuatro factores, obteniendo como conclusión, que el factor de riesgo de mercado es el mejor factor en el periodo completo de estudio al igual que el factor de riesgo de tamaño (SMB), y un menor desempeño el factor de valor (HML). Finalmente, el factor momentum (WML) no obtuvo significancia estadística. El rendimiento del modelo analizado por medio del coeficiente de determinación (R^2) obtiene que el modelo de cuatro factores obtiene un notable rendimiento en predicción, en el período posterior a la crisis Subprime. (Bortoluzzo, Venezuela, Bortoluzzo, & Nakamura, 2016). Otra investigación en el mercado bursátil de México, utilizando un periodo que va desde 1997 a 2018, en frecuencia mensual, obtiene que los factores del modelo de Fama y French de tres factores son todos significados (RM-RF, SMB, y HML), si bien es cierto el estudio agrega factores macroeconómicos, como riesgo país y tasa de interés, estos factores agregan un menor aporte a los factores originales del modelo en el período en estudio. (Saucedo & González, 2021).

Al igual que este estudio, otra investigación somete a estudio los modelos de valoración derivados del CAPM, con datos de la bolsa de valores de Johannesburgo (Sudáfrica), con datos de 2000 y 2016, obtiene como resultados que el modelo Fama Carhart de cuatro factores es el mejor modelo para usar en todas las condiciones del mercado. (Mukoyi & Ogujiuba, 2022). En periodo similar otro estudio en la bolsa de valores de Marruecos (con periodo 2003 a 2017), obtiene también que el modelo de Fama Cahart de cuatro factores obtiene el mejor rendimiento. (Benali, Lahboub, & El Bouhadi, 2023). Al igual que esta investigación en el mercado chileno, pero en período de crisis. Con respecto al modelo de cinco factores un estudio reciente aplicado a mercados bursátiles latinoamericanos, entre ellos incluido Chile, México, Colombia y Perú, somete a estudio al modelo de cinco factores en el período de 1999 y 2017, obteniendo

como conclusión que el modelo obtiene un mejor desempeño. (De Carvalho, Fernandes Amaral, Lima Pinheiro, & Ferraz Correia, 2021)

Como conclusión y respondiendo la pregunta planteada en la investigación de: ¿qué modelo captura mejor rendimiento en la predicción de los retornos de los activos que componen el índice IPSA de la bolsa de valores de Santiago de Chile?, es la siguiente: En el mercado chileno analizado es recomendable utilizar el modelo de Fama French de cinco factores en periodos sin pandemia, sin embargo, en períodos de crisis sanitaria, cuando las políticas públicas del país realicen cuarentenas o cierre de varias actividades de la comunidad, se propone utilizar el modelo de Fama Cahart de cuatro factores.

Capítulo 5 : Sentimiento de los inversores en la crisis sanitaria y comportamiento de los índices bursátiles del MILA

5.1.-Resumen del capítulo

Este trabajo analiza la volatilidad de los mercados de valores, específicamente los índices que componen el Mercado Integrado Latino Americano (MILA), compuesto por índices bursátiles de Chile, Colombia, México y Perú, en período de crisis sanitaria del COVID-19. Con el propósito de encontrar indicadores que capturen el temor de los inversionistas en tiempos de alta volatilidad provocada por la crisis, con el fin de recopilar información relevante para la valoración de los activos. En esta etapa la investigación resuelve la siguiente interrogante: ¿Cuál o cuáles factores exógenos al modelo de valoración, poseen información relevante, en situación de pandemia?

El estudio utiliza como metodología el modelo de autorregresión vectorial (VAR), utilizando datos diarios desde marzo de 2020 a mayo de 2021 de todos los índices, sometiendo a la causalidad de Granger los factores utilizados.

Los hallazgos que se obtienen son los siguientes:

- 1.- los índices de volatilidad VIX y la volatilidad V2X de la eurozona, tienen información relevante para índices bursátiles de Chile, Colombia y México al comprobarse la causalidad entre las variables y los índices bursátiles.
- 2.- El factor de SP&500 Twitter Sentiment Index, resulta estadísticamente significativo para Chile, Colombia y Perú, como también el índice del miedo del mercado de las criptomonedas Fear and Greed.
- 3.- El factor construido a partir de los nuevos casos confirmados a nivel mundial de la pandemia, presentan causalidad sobre los índices de Chile, Colombia y México, y la cantidad de nuevas muertes sólo para el índice de México.

Por lo tanto, el estudio indica que es necesario ir incorporando a los modelos de valoración estos factores en los mercados sometidos a estudio, en situación de crisis sanitaria, con el objeto de que los modelos tengan un mejor rendimiento en la predicción de los precios de los activos.

5.2.-Introducción

La irrupción del COVID-19 provocó grandes trastornos e incertidumbres en la vida de las personas y en los mercados financieros. Hay argumentos para creer que la pandemia alteró la predisposición de los ciudadanos para participar en actuaciones inciertas que ofrecen la posibilidad de una pérdida o ganancia financiera. Uno de esos motivos es la velocidad a la que las noticias sobre el virus se propagan entre la población (Heo, Grable & Rabbani, 2020)

Este trabajo busca revisar factores de riesgo que puedan dar cuenta de mejor forma la reacción del mercado de valores de países en vías de desarrollo a la crisis sanitaria. Utilizamos factores actuales que contribuyen a explicar las pérdidas de la gran mayoría de los activos que conforman los índices bursátiles. El objetivo es la búsqueda de variables explicativas para los modelos de valoración hacia efectos de predicción de los precios de los activos en período de crisis sanitaria, donde se aprecia una gran volatilidad y pérdidas en los rendimientos de las acciones.

Las caídas en los rendimientos de las bolsas de valores mundiales han sido comparadas con las mayores crisis que ha vivido este mercado en los registros que se tienen disponibles, por lo tanto es importante buscar otras variables asociadas directa o indirectamente a la crisis financiera, en lo referente a sentimientos del inversor que puedan tener una causalidad en los índices que componen el Mercado Integrado Latino Americano (MILA), y que se puedan incluir en estudios posteriores en un modelo de valoración de activos, para periodos de emergencia sanitaria.

Este estudio utiliza los índices de volatilidad detectada, ya sea en mercados desarrollados como en mercados emergentes y en la eurozona, denominados VIX. Además, se examinan información que actualmente son candidatos para capturar el sentimiento de los inversionistas, como lo son la redes sociales o índices que capturan temor en mercados de divisas. Esto es relevante en el sentido de ir incorporando nuevos elementos de análisis que permitan agregar información acerca de la racionalidad de los agentes en su toma de decisiones. No se trata solo de considerar la aversión al riesgo en la teoría financiera clásica, y pasar por alto el papel del sentimiento de los inversores. Esto último podría conducir a una imagen imperfecta en la descripción del precio de los activos. (Apergis & Rehman, 2018)(Rehman Muhammad, 2021) (Yu, 2021) (Chen & Haga, 2021) (Sibley, Wang, Xing, & Zhang, 2016)

No en todas las zonas geográficas el COVID-19 ha causado el mismo daño en los mercados financieros. Así, por ejemplo, América Latina y el Caribe (ALC) es la región más golpeada por la pandemia, la fuerte contracción provocada por la crisis sanitaria ha tenido enormes costos económicos y sociales, ya que, llegó después de varios años de un débil desempeño económico, con un bajo crecimiento promedio y escaso progreso en los indicadores sociales, con un periodo de agitación social que sacudió a algunos países a finales de 2019.

Es de suponer que la crisis del COVID-19 tendrá un impacto a largo plazo sobre las economías de la región. Es probable que los menores niveles de aprendizaje y de empleo reduzcan los ingresos futuros, mientras que el elevado nivel de endeudamiento público y privado puede causar tensión en el sector financiero y frenar la recuperación.

En la búsqueda de nuevos factores que capten de mejor forma el riesgo en periodo de crisis sanitaria, probando índices de volatilidad, índices de redes sociales, índice de miedo y la codicia a través del mercado de las criptomonedas (centrado en el Bitcoin) e índices creados para esta investigación con datos que provienen de la pandemia. Para llevar a cabo esta tarea se utilizará la prueba de causalidad de Granger ([Granger, 1969](#)), previo análisis de las series de tiempo, para poder asegurar que el estudio obtenga causalidades y no casualidades entre los datos analizados. Las series de datos que se somete a análisis es diaria y comprende al periodo del 3 de marzo de 2020 hasta el 20 de mayo de 2021 y se aplicará un proceso estadístico para explicar la consistencia de datos. Para llevar a cabo la aplicación de causalidad, en primer lugar, se debe revisar que las series de tiempo estén en condiciones de poder someterlos a la metodología VAR (Vectores Auto Regresivos), para esto se aplica el test de raíz unitaria a los datos por medio de la prueba de Dickey Fuller aumentada. ([Dickey & Fuller, 1979](#))

Para el caso de la causalidad de dos variables, la sola existencia de una correlación entre dos variables no implica causalidad. Es decir, que una variable se correlacione con otra no implica siempre que una de ellas sea la causa de las alteraciones en los valores de otra. ([Montero, 2013](#)). El tiempo no corre hacia atrás. Es decir, si un acontecimiento A sucede antes de un suceso B, es posible que A cause B. Sin embargo, no es posible que B provoque A. En otras palabras, los acontecimientos pasados pueden propiciar sucesos que ocurren en la actualidad. Lo cual no sucede con los sucesos futuros. Es la idea general de la llamada prueba de causalidad de Granger. ([Granger, 1969](#)).

Este trabajo obtiene que en los mercados estudiados, los indicadores que de volatilidad, explican las variaciones del mercado como lo han comprobado otros estudios (Sarwar, 2019) (Yang, Zhou, & Xin, 2019) (Sakowski, Ślepaczuk, & Wywiół, 2016) (Chen & Ray-Wang, 2020).

La información obtenida desde las redes sociales como lo es Twitter permite la construcción de un índice que se crea a partir de comentarios bursátiles acerca de los activos que componen el índice SP&500. Existen investigaciones que utilizan este índice y logran establecer que hay información útil para tres mercados sometidos a análisis: Chile, Colombia y México (Groß-Klußmann, König, & Ebner, 2019) (Cole, Daigle, & Van Ness, 2015) (Kim & Youm, 2017) (Azar & Andrew W., 2016).

La construcción de índices a partir de la información de la pandemia, que son la cantidad diaria de nuevos casos y cantidad de nuevas muertes a causa del COVID-19. Este factor de riesgo es utilizado por estudios que dan cuenta que en tres mercados los casos diarios de COVID-19 a nivel mundial entregan información útil en la valoración y predicción de activos, al igual que otros estudios realizados en otros mercados (Just & Echaust, 2020) (Yu G. , 2020) (Rahman, Guotai, Gupta, Hossain, & Abedin, 2021) (Robin, 2021) (Alber, 2020) (Algamdi, Mokhtar Brika, Musa, & Chergui, 2021).

La prueba de índices que capturan el miedo de los agentes de los mercados, como lo son los movimientos de las criptomonedas, mercado altamente volátil, especialmente del Bitcoin. Es utilizado en estudios que someten al índice del miedo y la codicia en la búsqueda de más información que expliquen los movimientos de las inversiones, capturando el sentir de los inversionistas (Derya, 2021) (Chen, Shan, & Wang, 2021)

Esta investigación va en la dirección de la búsqueda de nuevos factores que permitan poner a prueba la racionalidad de los agentes en el mercado, y de esta forma obtener información relevante que no se obtiene con los factores de riesgo tradicionales, para entender de mejor forma las decisiones financieras que no necesariamente son racionales, sino que también son emocionales, afectivas, sentimentales axiológicas, etc. (Ortiz, 2019).

Hoy en día es posible rescatar información desde redes sociales e interacción desde las plataformas tecnológicas, esto abre un horizonte amplio e interesante para buscar más factores que puedan ayudar a que variables exógenas puedan

reemplazar el supuesto de aversión al riesgo de los agentes del mercado y mejorar el rendimiento de los modelos de valoración.

El estudio obtiene como hallazgos que los índices VIX, V2X, SP&500 Twitter Sentiment, el Fear and Greed Index y el índice creado a partir de los nuevos casos de COVID-19 a nivel mundial, denominados índices del miedo que en cierta medida rescatan el comportamiento de los inversionistas, contienen información relevante para los mercados del MILA y pueden ser parte de investigaciones donde los agreguen a los modelos de valoración tradicionales, como nuevos factores de riesgo en tiempo de crisis.

5.3.-Revisión de Literatura

En la literatura previa se ha investigado sobre los cambios que producen los sentimientos de los inversores en el precio de las acciones, obteniendo evidencias de que los cambios en el sentimiento provocan fluctuaciones en el precio de las acciones (Yuang 2018; Chen & Zeng, 2018). Más en concreto, se ha examinado el impacto del COVID-19 en el sentimiento de los inversores chinos y el comportamiento del precio de las acciones con una perspectiva basada en eventos (He, Xu & Zhan, 2022). Es en este campo donde se encamina la presente investigación.

Al revisar las investigaciones recientes varios trabajos mencionan la búsqueda de variables que puedan explicar las variaciones de los activos, uno de ellos no encuentra causalidad entre las variables del número de nuevos casos y cantidad de muertes por COVID-19, con respecto al índice de la Bolsa de valores de Rumania (BET) (Gherghina, Armeanu, & Joldes, 2021). La información de la pandemia ha contribuido para explorar la construcción de factores de riesgo, orientado a obtener un mejor rendimiento de los modelos de valoración en crisis sanitaria, un estudio realizado a nivel de condados de EE. UU., construyeron factores de riesgo a partir de la cantidad de nuevos casos y muertes a causa del COVID-19, como también la cantidad de búsquedas en Google acerca de consultas del mercado de valores. Este estudio obtiene como hallazgo que los casos nuevos y muertes ocasionadas por la pandemia, como la actividad de búsqueda en el motor de búsqueda de Google, mejoran significativamente los modelos de pronósticos de precios anormales de acciones en el largo plazo (Dey, Hoque, & Das, 2020).

En la misma idea de construir factores de riesgo a través de la información de la pandemia, un estudio en búsqueda de mejorar el pronóstico de las fluctuaciones

del índice SP&500, por medio del método de causalidad de Granger verifica si los nuevos factores poseen información relevante en el mercado de valores de EE. UU. El estudio obtiene como hallazgo que la transmisión de la crisis sanitaria en el mundo es importante para explicar las fluctuaciones del mercado financiero, además los investigadores enfatizan en la importancia de la cooperación a nivel internacional para garantizar la calidad y disponibilidad global de los datos de salud, para emplearlos entre otras cosas como factores de riesgo en los mercados financieros (Matos, Costa, & da Silva, 2021).

Otros estudios, además de los datos de pandemia, analizan como factor los datos de cambios de temperatura a causa del cambio climático, específicamente investigan la relación entre tipo de cambio de la moneda de Mozambique, frente al dólar estadounidense, junto con la cantidad de nuevos casos y de muertes a causa del COVID-19 y la temperatura en grados centígrados. Utilizando el método VAR (Vectores Autorregresivos) y causalidad de Granger. Concluyendo que hay una relación de causalidad unidireccional entre la cantidad de muertes por causa de COVID-19, el tipo de cambio, y de temperatura con la variable de cantidad de muertes por COVID-19, determinando que la cantidad de muertes por COVID-19 es una variable relevante para el pronóstico del tipo de cambio y la temperatura influye en las muertes por la pandemia (Langa, Massuanganhe, & Nhanala, 2022) (Bal & Mohanty, 2021).

Otro estudio que analiza los efectos de la pandemia en los commodities (plata y petróleo), por medio de la metodología VAR concluye que hay un efecto negativo a corto plazo de la tasa de propagación del COVID-19, en la variación de los índices bursátiles de los commodities sometidos a estudio, por lo tanto, sirve para explicar los cambios en los precios de éstos. (Riveros & Hassan, 2021).

El brote del COVID-19 trae consigo una cadena de reacciones adversas y alteraciones de mercado, en este sentido un estudio que analiza estas reacciones utilizando indicadores del medio ambiente, salud, el mercado del petróleo y energía, utilizando el modelo ADRL (Autorregresive Distributed Lag) y la prueba de causalidad de Granger. Obtiene como hallazgo, que no existe una conexión causal significativa entre la crisis sanitaria, el medio ambiente, el sector de la salud, la industria del petróleo y la energía. (Armeanu, Gherghina, Andrei, & Joldes, 2022)

Hoy en día el uso de las redes sociales se ha convertido en una fuente de datos e información fundamental para saber hábitos de consumo y comportamientos,

utilizados en campañas políticas y de marketing. Estas preferencias de las personas permiten hoy construir factores de miedo frente a las crisis financieras locales o globales.

Un estudio que está inspirado en la hiperrealidad de Baudrillard propone que los efectos económicos y financieros de la pandemia tienen que ver con la búsqueda de una relación entre las emociones que son capturadas desde las redes sociales. Los hallazgos que obtienen es una relación entre la intensidad de uso de Twitter y la tendencia del mercado de valores, por medio de la aplicación de la prueba de Granger ([Lazzini, Lazzini, Balluchi, & Mazza, 2021](#)).

Otros estudios exploran la relación del sentimiento de inversores extraídos desde Twitter, y probados en el índice SP&500 y la rentabilidad del oro, buscando la causalidad bilateral entre los sentimientos de los inversionistas y los rendimientos del oro para predecir los rendimientos del SP&500, además de la influencia de los rendimientos del oro sobre la volatilidad del índice mediante la utilización de modelos ARIMA y de la prueba de causalidad de Granger, obteniendo como hallazgo que el sentimiento y los rendimientos del oro predicen los rendimientos del índice S&P500. ([Piñeiro, López, Pérez, & Ribeiro, 2018](#)).

Un estudio que investiga el impacto del miedo a la pandemia en la rentabilidad de acciones construyó un índice único del miedo acerca de la pandemia del COVID-19, basado en el índice de volumen de búsqueda (SVI) de Google Trends, mediante la búsqueda de palabras relacionadas con la crisis sanitaria, en el mercado. La cantidad de búsquedas de acuerdo con un patrón definido se utiliza como un proxy para medir el estado de ánimo de los inversionistas minoristas durante el periodo de pandemia, da cuenta que estos datos influyen en los precios de los activos de Estados Unidos. Este resultado es útil para los administradores de carteras, ya que, el índice del miedo de COVID-19, es un buen predictor para el precio de las acciones en tiempo de pandemia. ([Subramaniam & Chakraborty, 2021](#)).

Es importante también destacar los estudios de causalidad mediante la prueba de Granger, donde buscan causalidad entre los índices de volatilidad o índice del miedo (VIX: global, VXXLE: mercados emergente), el índice orientado a las eurodivisas (EVZ), índice del miedo del mercado del oro (GVZ) y el Rastreador de volatilidad del mercado de acciones por enfermedades infecciosas (EMV-ID), donde obtienen como hallazgo que el sector energético tiene mayor explicación con el índice del miedo del oro, y el miedo del mercado de valores debido a

enfermedades infecciosas (EMV-ID), y el miedo del mercado global (VIX) son responsables del temor expresado en volatilidad en prácticamente todos los demás mercados financieros analizados durante el período de pandemia de COVID-19 (Adekoya & Oliyide, 2022).

Otras formas de estudios es la de contagio entre bolsas de valores en medio de la crisis sanitaria, donde se utilizan los índices de SP&500 de Estados Unidos, VN-Index de Vietnam y el PSEi de Filipinas, encontrando que no hay evidencia de contagio de la bolsa de EE. UU., con el mercado de Filipinas, pero con respecto al mercado de valores filipino existe contagio, y entre el mercado de filipinas y Vietnam están influenciados por el efecto de contagio en la crisis pandémica de COVID-19. (Le & Tran, 2021).

En periodos de tensión de los mercados, los inversores se refugian en los commodities, especialmente el oro, para mitigar el riesgo, provocando mayor volatilidad del metal.

Un estudio, además de analizar las interacciones entre las volatilidades del mercado de valores (VIX), del oro (GVZ) y el petróleo (OVX), obtienen que existe una mayor causalidad entre el mercado de valores de Estados Unidos, y el mercado de commodities (oro y petróleo), durante la crisis del COVID-19 (Lowen, Kchouri, & Lehnert, 2021).

Otro estudio que busca la causalidad no lineal entre la incertidumbre por enfermedades infecciosas y la correlación entre acciones y bonos. Obteniendo como hallazgos que la incertidumbre debido a enfermedades infecciosas tiene un valor predictivo significativo sobre los cambios en la rentabilidad en de acciones y bonos (Gkillas, Konstantatos, & Siriopoulos, 2021).

Otra investigación realizada en Chile, sobre la causalidad del índice rastreador de volatilidad del mercado de valores de enfermedades infecciosas (EMV-ID), mediante la utilización de un procedimiento autorregresivo condicional y la prueba de causalidad de Granger, concluye que este índice tiene causalidad con la volatilidad del mercado chileno en periodo de crisis sanitaria. (Romero, Coronado, & Ibañez, 2021).

También es necesario mencionar que la búsqueda de la causalidad en variables de otros mercados financieros en tiempos de pandemia o crisis financieras como en la crisis sub prime, donde se explora la causalidad entre los tipos de cambios y la dinámica de los mercados bursátiles en los países de la Eurozona utilizando

la prueba de Granger entre la bolsa española y tipos de cambios (EUR/USD, EUR/JPY, EUR/CNY y EUR/GBP), obteniendo como hallazgos de las relaciones analizadas son significativas solo en el subperíodo de crisis (2008-2015) (Luzarraga, Regúlez, & Rodríguez, 2021).

5.4.-Datos y Metodología

5.4.1.-Mercado integrado Latinoamericano

Dentro del marco de la Alianza del Pacífico y de manera particular en el frente financiero se han logrado avances en la implementación del Mercado Integrado Latinoamericano – MILA que mediante cambios regulatorios han permitido el inicio de la negociación bursátil de títulos de renta variable entre los cuatro países (Chile, Colombia, México y Perú).

El objetivo del MILA es llegar a ser un polo de inversión relevante en la región, teniendo como característica de ser la primera iniciativa de integración bursátil transnacional sin fusión o integración corporativa a nivel global, mediante la utilización de tecnología de información y de armonización de la regulación para la negociación de mercados de capitales y custodia de títulos de los cuatro países.

MILA comenzó sus operaciones el 30 de mayo de 2011 como resultado de un acuerdo entre Bolsa de Santiago, la Bolsa de Valores de Colombia y la Bolsa de Valores de Lima, así como de los depósitos Deceval, DCV y Cavali. Fue una iniciativa privada en su origen.

En la tabla 5.1, se describen los indicadores que se utilizarán para la investigación, estos son: los indicadores bursátiles de los cuatro países latinoamericanos y los indicadores del miedo, datos de la pandemia (nuevos casos y nuevas muertes diarias causadas por el COVID-19 a nivel mundial), que se han ido desarrollando para analizar la pertinencia de su utilización como factores de riesgos para predecir el comportamiento de los activos, en esta ocasión se utilizan, para analizar si poseen información relevante acerca de los índices de las bolsas latinoamericanas que componen el mercado MILA, en tiempo de crisis sanitaria.

Variable	Descripción
IPSA	Índice de Precios Selectivo de Acciones. Mide las variaciones de precios de las empresas emisoras chilenas más grandes y líquidas listadas en la Bolsa de Santiago.

COLCAP	Índice bursátil de la Bolsa de Valores de Colombia. Refleja las variaciones de los precios de las 20 acciones más líquidas, donde el valor capitalización bursátil ajustada de cada compañía determina su participación dentro del índice.
S&P_BMV IPC	El S&P/BMV IPC (Índice De Precios y Cotizaciones) busca medir el desempeño de las acciones de mayor tamaño y liquidez listadas en la Bolsa Mexicana de Valores. Su objetivo es proporcionar un índice amplio, representativo, pero al mismo tiempo fácilmente replicable, que abarque el mercado bursátil mexicano.
S&P Perú Select Index	El S&P/BVL Perú Select Index busca medir el desempeño de las empresas de mayor tamaño y liquidez listadas en la Bolsa de Valores de Lima (BVL).
NC	Nuevos Casos de COVID-19 en el mundo.
ND	Nuevas Muertes por COVID-19 en el mundo.
EMV-ID	Rastreador de volatilidad del mercado de acciones por enfermedades infecciosas.
VIX	Índice de Volatilidad mide la volatilidad de las opciones del mercado de Chicago (CBOE o Chicago Board Options Exchange) en el índice S&P500 (Standard & Poor's 500).
VXEEM	Índice de volatilidad (VIX), mide la volatilidad en los mercados emergentes
V2X	Índice de volatilidad (VIX), mide la volatilidad en la Eurozona
SP&500 Twitter Sentiment Index	El S&P 500® Twitter Sentiment Index está diseñado para reflejar el rendimiento de los 200 componentes del S&P 500 con el sentimiento más positivo en Twitter.
Fear and Greed Index	Recopila datos de cinco fuentes. Cada punto de datos se valora igual que el día anterior para visualizar un progreso significativo en el cambio de sentimiento del mercado criptográfico.

Tabla 5.1: Indicadores de bolsas Latinoamericanas, índices del miedo e indicadores de pandemia

Para los índices se calcula el retorno de la siguiente forma:

$$R = \ln\left(\frac{P_t}{P_{t-1}}\right) \quad 5.1$$

Donde (Ecuación 5.1): R : Retorno, P_t : Corresponde al precio de un activo en el mercado de valores en período t , P_{t-1} : Precio corresponde al precio del activo en el mercado de valores en el período $t-1$, se utilizan los retornos con logaritmos para obtener el retorno compuesto continuo, el cual supone que sigue una distribución normal, además tiene una ventaja que es la posibilidad de sumar rentabilidades en el tiempo, logrando agrupar rentabilidades en totalizadores de rentabilidad.

$$NC = \ln\left(\frac{CNC_t}{CNC_{t-1}}\right) \quad 5.2$$



Donde (Ecuación 5.2), CNC_t es la cantidad de casos nuevos confirmados de COVID-19 en tiempo t , CNC_{t-1} , es la cantidad de casos nuevos confirmados en tiempo $t-1$, esta variable mide el cambio entre los casos de covid en tiempo t (un día) y en tiempo $t-1$ (día anterior).

$$DC = \ln\left(\frac{DNC_t}{DNC_{t-1}}\right) \quad 5.3$$


Donde (Ecuación 5.2), DNC_t es la cantidad de casos de muertes confirmadas a causa del COVID-19 en tiempo t , DNC_{t-1} , es la cantidad de casos muertes confirmadas en tiempo $t-1$, esta variable mide el cambio entre los casos de covid en tiempo t (un día) y en tiempo $t-1$ (día anterior).

En la figura 5.2, se muestra la evolución de los precios de los índices sometidos a estudio, estos precios se obtienen en periodicidad diaria en el intervalo de tiempo comprendido entre marzo de 2020 y mayo de 2021 desde el sitio Investing.com (Investing.com, 2021).

Figura 5.1: Evolución de precios de los índices que compone el mercado integrado Latinoamericana, Elaboración propia por medio de Rstudio.




Evolución SP BMV IPC - Período de Estudio



Fuente: Elaboración Propia: Datos: investing.com

Evolución SP Perú Select - Período de Estudio



Fuente: Elaboración Propia: Datos: investing.com

Adicionalmente, se utilizarán otras variables que relacionarán el riesgo con la situación pandémica. Se tomarán los datos de nuevos casos y nuevas muertes a causa del COVID-19 a partir de los datos extraídos de Our World Data ([COVID-19, 2021](#)), son datos diarios y a nivel mundial. La evolución de casos nuevos confirmados y de muertes a causa del COVID-19 en el período de estudio se muestra en la figura 5.2. Donde se pueden ver los incrementos de nuevos casos diarios de COVID-19 y la cantidad de muertes a causa de la pandemia a nivel mundial en el periodo de estudio entre marzo de 2020 y mayo de 2021.

Figura 5.2: Nuevos casos y muertes diarias a causa del COVID-19, Elaboración propia.
Software utilizado RStudio.


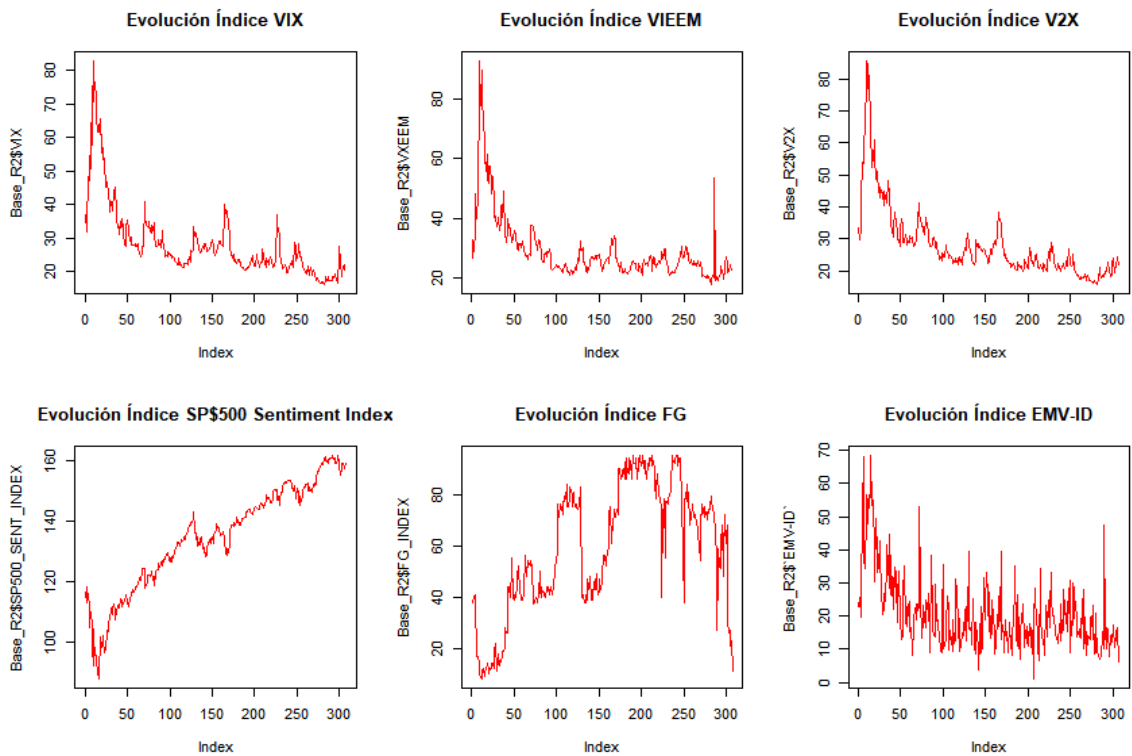


Figura 5.3: Evolución de índices que capturan el miedo de mercados de valores y criptomonedas, Elaboración Propia. Software utilizado RStudio.



En la figura 5.3, se puede ver la evolución de los índices VIX, el SP500 Sentiment Index y EMV-ID para el período en estudio, los índices de volatilidad (VIX, VIEEM, V2X) presentan una gran volatilidad al inicio del periodo, bajando la volatilidad posterior a marzo de 2020. Sin embargo, el índice de volatilidad de mercados emergentes presenta mayor inestabilidad en 2021. Con respecto al Índice SP&500 Twitter Sentiment, que mide el rendimiento de las 200 empresas más importantes del índice SP&500 basado en como los usuarios de la red social están analizando las acciones de acuerdo con sus mensajes (Tweet), se puede ver una caída del indicador al principio del tiempo estudiado, recuperándose en el periodo de 2021. Con respecto al índice Fear and Greed, en todo el periodo muestra mayor volatilidad, finalmente el comportamiento del indicador rastreador de volatilidad del mercado de valores de enfermedades infecciosas, indica mayor riesgo en el inicio del período en estudio.

5.4.2.-Prueba de causalidad de Granger

Se utilizará un modelo Vector Autorregresivo (VAR) bivariado para analizar el efecto de los factores de riesgo sometidos al estudio, sobre los cambios en el valor de los índices latinoamericanos. Este modelo fue creado por Sims y ha sido ampliamente utilizado en finanzas y economía (Sims, 1980). El VAR presenta alternativamente un sistema de ecuaciones simultáneas en donde cada una de las variables son explicadas por sus propios rezagos. Es decir, no se admite restricciones a priori y todas las variables son consideradas endógenas. Las variables explicativas del sistema son predeterminadas (endógenas rezagadas); además, los errores tienen una varianza constante y no presentan autocorrelación. Por ello, el mejor estimador asintótico de este modelo es el de rezagos de las variables explicativas que se incorporan en cada ecuación. (Trujillo, 2010), este modelo se representa por:

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \epsilon_t, \epsilon_t \sim W.N.(\Omega) \quad 5.3$$

Donde:

N: es el número de variables examinadas.

y: n*1 vector de variables relevantes.

c: n*1 vector de constante.

ϕ_1 : n * Coeficiente de la matriz

VAR consta de n modelos de regresión, con regresión de cada variable en constantes y rezagos de todas las variables. En este artículo usaremos el modelo VAR Bivariado:

$$\begin{aligned} y_{1t} &= c_1 + \phi_{11}y_{1,t-1} + \phi_{12}y_{2,t-1} + \phi_{21}y_{1,t-2} + \phi_{22}y_{2,t-2} + \epsilon_{1t} \\ y_{2t} &= c_2 + \phi_{21}y_{1,t-1} + \phi_{22}y_{2,t-1} + \phi_{11}y_{1,t-2} + \phi_{12}y_{2,t-2} + \epsilon_{2t} \end{aligned} \quad 5.4$$

$$\begin{pmatrix} \epsilon_{1t} \\ \epsilon_{2t} \end{pmatrix} \sim W. N. \left(\begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{12} & \sigma_2^2 \end{bmatrix} \right)$$

Tres herramientas que son fundamentales para el análisis VAR. Son la causalidad de Granger, función de respuesta al impulso y descomposición de la varianza. La causalidad de Granger determina si una variable es útil para pronosticar otra variable. (Granger, 1969). En este sentido, lo que se quiere probar con este trabajo es si a partir de un nuevo caso de coronavirus y demás índices de volatilidad y/o del miedo, causan un cambio en los índices latinoamericanos que componen el MILA, si esto ocurre, los cambios en los índices se pueden pronosticar a partir de la información obtenida en el pasado de los factores de riesgo a partir de datos de pandemia e índices de volatilidad.

5.4.3.-Pruebas de estacionariedad

Las series de precios son útiles para visualizar por medio de gráficos de tendencia e intuitivamente verificar la existencia de estacionariedad, estos dan una pista inicial al visualizar la tendencia, puede indicar inicialmente que está variando la media y los precios tienen un comportamiento de caminata aleatoria. Otro método es por medio de revisión de autocorrelación, a partir del correlograma, si la autocorrelación es baja y se mantiene en la media indica que es una serie estacionaria, si muestra mucha variación estaría indicando que estamos en presencia de una serie de tiempo no estacionaria. Luego existen otras técnicas suscritas al análisis más fundamental que serán indicadas a continuación.

5.4.4.-Test de Dickey-Fuller (DF)

Para determinar si un proceso es o no estacionario podemos utilizar la prueba de raíces unitarias Dickey - Fuller (DF) o Dickey-Fuller aumentado (ADF). (Dickey & Fuller, 1979). Ellos desarrollaron estos test en modelos para realizar el análisis de la estacionariedad a los procesos estocásticos.

El planteamiento del modelo es el siguiente:

$$z_t = a_1 z_{t-1} + v_t \quad 5.5$$

Si a_1 es menor a 1 la variable z_t está correlacionada, pero será estacionaria mientras que si es igual a 1 o mayor será no estacionaria y su variancia crecerá de forma explosiva.

La hipótesis por contrastar es:

$$H_0: a_1 = 1 \text{ Versus } H_1: a_1 < 1$$

En un proceso auto regresivo AR(1) y para realizarlo se utiliza la relación de la ecuación (3) donde $\nabla = z_t - z_{t-1}$ y $d_1 = a_1 - 1$, el parámetro d_1 tomará valores en el intervalo comprometido entre dos y cero, $-2 < d_1 < 0$, si el valor absoluto del parámetro a_1 , es menor que la unidad $-1 < a_1 < 1$.

La prueba DF consiste en contrastar:

$$H_0 : d_1 = 0 \text{ Tiene Raíz unitaria.}$$

$$H_1 : d_1 < 0 \text{ No tiene Raíz unitaria.}$$

5.4.5.-Test de Dickey-Fuller Aumentado (ADF)

El test ADF también consiste en el mismo objetivo del test DF: Contrastar la hipótesis de nulidad de d_1 , pero en una relación aumentada con la inclusión de valores retardados de ∇z_t , si se considera necesario pueden incluirse también el término constante (drift) y la tendencia, igual que el test DF, de forma que el contraste, en caso de un aumento de dos retardos, se realiza en la relación:

$$\nabla z_t = d_1 z_{t-1} + d_0 + d_2 t + d_3 \nabla z_t(-1) + d_3 \nabla z_t(-2) + \dots \quad 5.6$$

Los valores críticos más utilizados son los propuestos por MacKinnon (MacKinnon, 2010). Para este estudio se realizará por medio del software econométrico Eviews, con las salidas de las regresiones efectuadas. La hipótesis nula, o hipótesis a contrastar, es la de integración o no estacionariedad de la perturbación aleatoria frente a la alternativa de no integración o estacionariedad. (Jordan, 2012)

5.5.-Resultados

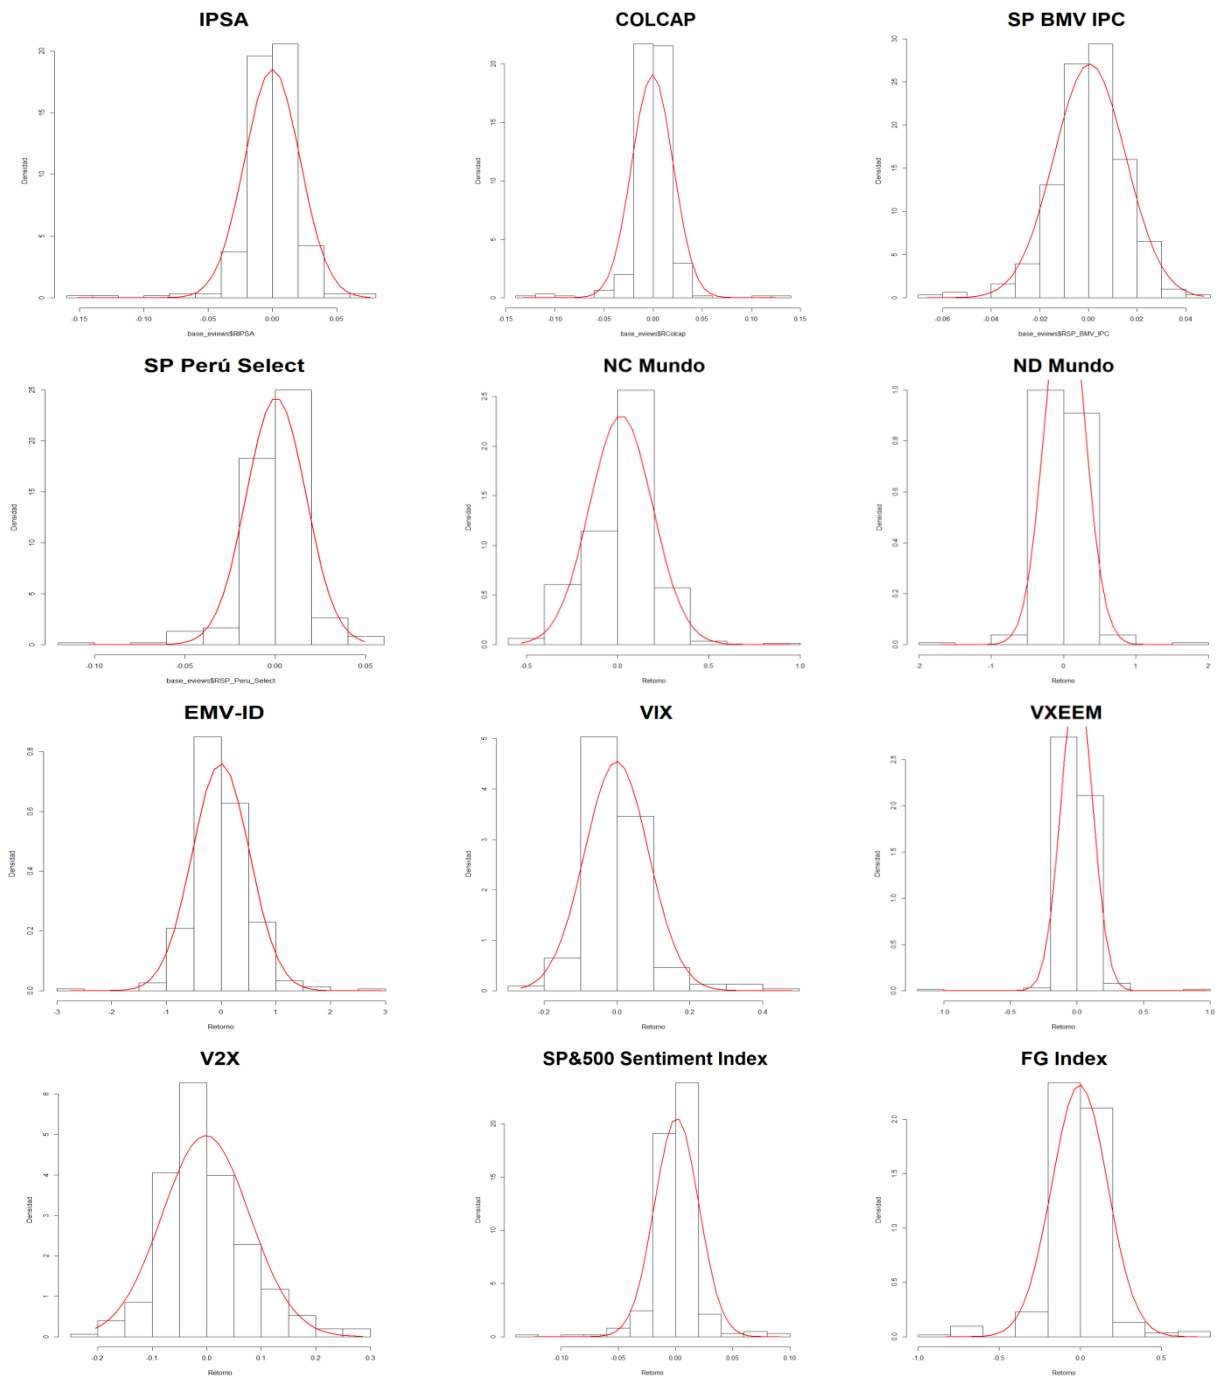
Variable	Media	Std. Dev	Skewness	Curtosis	Jarque Bera	Prob.
IPSA	-0,0002	0,022	-1,995	16,112	2395,09	0,000*
COLCAP	-0,0007	0,021	-1,052	19,900	3698,01	0,000*
SP_BMV_IPC	0,0006	0,015	-0,560	5,340	85,81	0,000*
SP_PERU_SELECT	0,0005	0,016	-1,328	10,225	755,52	0,000*
NC	0.0186	0.172	-0.039	5.678	91.55	0,000*
ND	0.0161	0.270	-0.295	10.370	697.13	0,000*
EMV-ID	-0.0044	0.524	0.304	8.103	336.87	0,000*
VIX	-0.0015	0.087	1.440	8.661	514.47	0.000*
VXEEM	-0.0010	0.115	-0.024	38.143	15746.80	0.000*
V2X	-0.0016	0.080	0.737	4.212	46.46	0.000*
SP&500 Twitter Sentiment Index	0.0010	0.019	-0.841	13.364	1405.80	0.000*
Fear and Greed Index	-0.0040	0.171	-1.047	10.965	865.01	0.000*

Tabla 5.2: Estadísticas de retornos de índices bursátiles del mercado integrado latinoamericano, índices asociados a enfermedades y sentimientos con respecto a bolsas y/o palabras claves de pandemia, además de dos indicadores de la pandemia de Nuevos Casos Mundiales y Nuevas muertes mundiales. Software utilizado Eviews.

*significancia estadística P-Value < 0,005

La serie temporal de la investigación corresponde a datos diarios de los índices que componen el mercado integrado latinoamericano MILA, en el periodo de marzo de 2020 al 20 de mayo de 2021, en Tabla 2 se muestran los estadísticos de las variables utilizadas y antes descritas, donde dos índices obtiene un promedio (media) negativo, IPSA, COLCAP, dos obtienen promedios positivos SP BMV IPC y SP PERU SELECT, con respecto a la volatilidad (Desviación Estándar) IPSA, y COLCAP son los índices que obtienen mayor volatilidad en el periodo, además se puede ver que el estadístico de asimetría (Skewness) de los índices son negativos. Esto indica que todos los índices tienen un sesgo negativo señalando una distribución con una cola asimétrica extendida hacia los valores negativos, de acuerdo con la curtosis, los datos están muy concentrados a la media de la distribución, por lo que las distribuciones de todos los índices son leptocúrticas. Por último, revisando el estadístico, Jarque Bera también indica una distribución leptocúrtica, por lo tanto, los valores de los estadísticos difieren de una distribución normal.

Figura 5.4: Gráficos de densidad de los rendimientos diarios de los índices que componen el índice MILA, elaboración propia, Software utilizado RStudio..





En la Figura 5.4, se comprueba que los valores se concentran en la media y se extienden los valores hacia los valores negativos, por lo tanto, los datos obtenidos

como también en la Tabla 5.2 y el análisis gráfico indican que los datos no se distribuyen normalmente.

Revisando los gráficos de los índices bursátiles latinoamericanos. El índice construido de nuevos casos presenta una distribución similar a los índices bursátiles, solo el índice V2X presenta una curva más achatada, pero según el estadístico Jarque Bera, también es una distribución leptocúrtica como las demás distribuciones analizadas.

Figura 5.5: Graficas de rendimientos diarios, fuente elaboración propio. Software utilizado RStudio.





En la figura 5.5, se muestran los gráficos de “Q-Q Plot” de los retornos de los índices en estudio, confirman la distribución detectada anteriormente de los índices latinoamericanos en el periodo de la investigación.

Para continuar con la investigación se necesita verificar la estacionariedad de las series utilizadas, donde es útil revisar la solidez de los datos, antes de ser sometidos a la prueba de causalidad, al igual que otros estudios acerca de causalidad o efectos de la pandemia realizados anteriormente. (Abuzayed, Bouri, Al-Fayoumi, & Jalkh, 2021) (Chaudhary, Bakhshi, & Gupta, 2020) (Dospatliev, Ivanova, & Varbanov, 2022) (Insaideo, Arthur, Amoako, & Andoh, 2021)

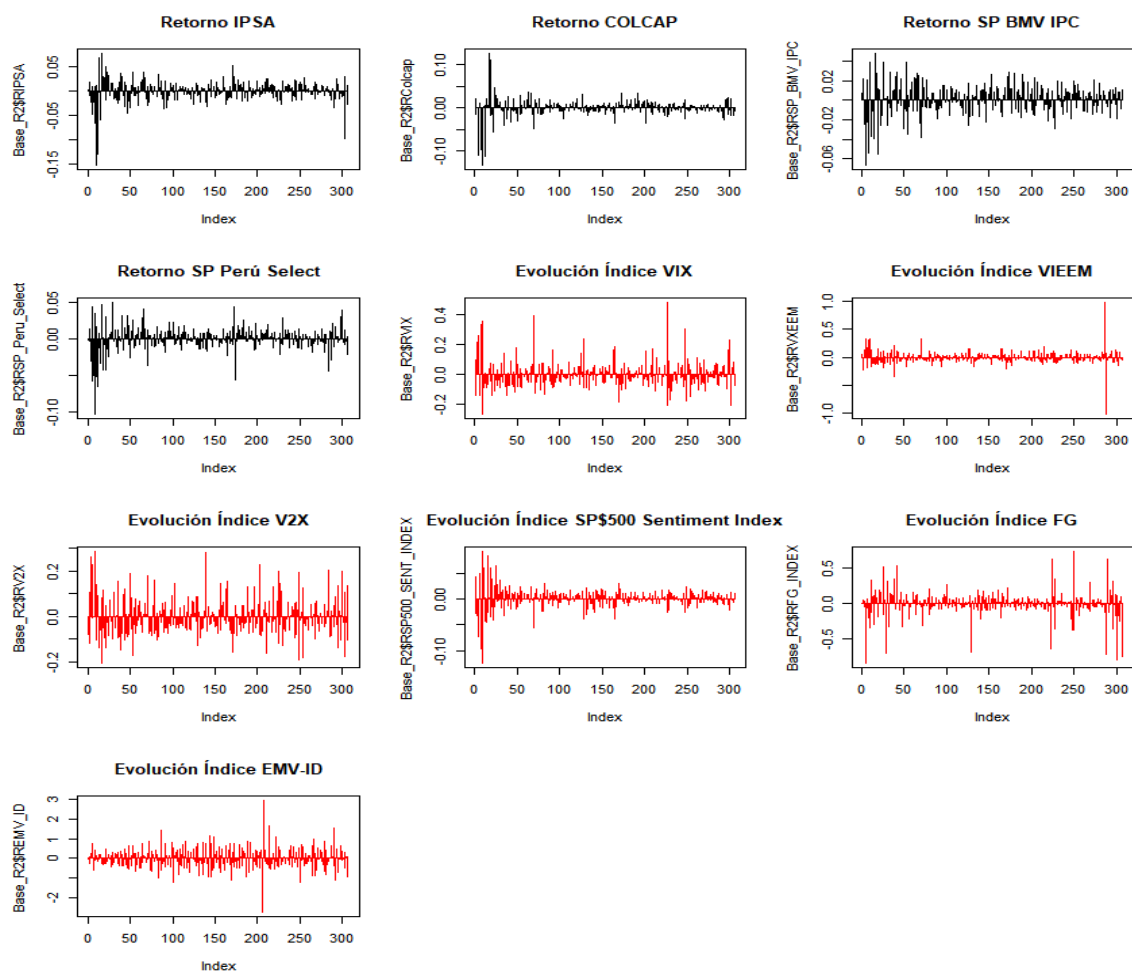
Variable	Probabilidad sin diferencia	Probabilidad Primera Diferencia	Orden de Integración
IPSA	0,4835	0,0000	I (1)
COLCAP	0,0591	0,0000	I (1)
S&P_BMV IPC	0,9349	0,0000	I (1)
S&P Perú Select Index	0,8489	0,0000	I (1)
NC	0,4527	0,0001	I (1)
ND	0,2584	0,0000	I (1)
EMV-ID	0,0377	0,0000	I (0)
VIX	0,3534	0,0000	I (1)
VXEEM	0,0918	0,0000	I (1)
V2X	0,2480	0,0000	I (1)
SP&500 Twitter Sentiment Index	0,8686	0,0000	I (1)
Fear and Greed Index	0,3441	0,0000	I (1)

Tabla 5.3: : Resultados del test de raíz unitaria Dickey Fuller Augmented (DFA). Software utilizado Eviews.

En la tabla 5.3, se muestran los resultados de la prueba de estacionariedad en el nivel y en la primera diferencia, así como también la integración de los índices bursátiles y factores de riesgo sometidos a estudio. Todos los índices bursátiles son estacionarios a la primera diferencia, mostrando el orden de integración de $I(1)$, en el caso de los nuevos casos de COVID-19 también son estacionarios, a la primera diferencia, en cambio, en el caso del índice volatilidad del mercado de acciones por enfermedades infecciosas resulta estacionario sin diferencia $I(0)$, por lo tanto, las series no son espurias y se puede continuar con el estudio.

En la Figura 5.6, se pueden ver las gráficas de los rendimientos diarios de los índices latinoamericanos que confirman los datos obtenidos, donde se muestran la evolución de las rentabilidades de los índices bursátiles y la evolución de las variaciones de índices de volatilidad y de miedo en el sector bursátil, como también la construcción de indicadores a partir de los datos de la pandemia.

Figura 5.6: Retornos diarios de los índices que someterán a estudio, fuente: Elaboración propia. Software utilizado RStudio.



Para revisar la heterocedastidad se examinan las siguientes variables AC (determining autocorrelation), PAC (partial autocorrelation) y Q test, el número de rezagos para la revisión de las series es de 20 y se presentan en la Tabla 5.4.

Variable	AC	PAC	Q-Stat	Probabilidad
IPSA	0.020	0.023	35.007	0.020*
COLCAP	-0.061	0.020	63.869	0.000*
SP BMV IPC	0.054	0.078	26.580	0.147
SP Select Perú	0.110	0.147	36.843	0.012*
NC	0.215	-0.036	259.57	0.000*
ND	0.218	-0.054	226.49	0.000*
EMV-ID	0.147	0.132	87.285	0.000*
VIX	-0.114	-0.126	34.308	0.024*
VXEEM	0.324	-0.033	2248.2	0.000*
V2X	0.418	-0.028	2846.8	0.000*
SP&500 Twitter Sentiment Index	-0.093	0.012	226.49	0.000*
Fear and Greed Index	0.051	0.056	44.597	0.001*

Tabla 5.4: Resultados de datos de correlograma aplicado por medio de Eviews, Fuente realización propia.

*significancia estadística P-Value < 0,005

Al revisar los resultados acerca de la correlación simple, parcial y de heterocedasticidad, donde todos los datos pueden aceptar la hipótesis nula de ausencia de autocorrelación serial, salvo en los datos correspondiente al índice SP BMV IPC, al menos en los 20 rezagos aplicados (si bien la serie muestra presencia de heterocedasticidad) estos pueden ser modelados por modelos ARCH, GARCH y es una condición necesaria para su aplicación, estos modelos nos permiten modelar la volatilidad a diferencia de los modelos lineales homocedásticos.

5.5.1.-Resultado de Causalidad de Granger

Antes de aplicar la prueba de causalidad de Granger se debe verificar si las series están cointegradas, para este análisis se realiza la prueba de cointegración de Phillips-Ouliaris (Phillips & Ouliaris, 1990), donde los resultados se presentan en la Tabla 5.5. Se someten los índices bursátiles latinoamericanos a la revisión con las variables que pueden ser factor de riesgo en el periodo de la pandemia, donde los resultados indican que se debe rechazar la hipótesis nula (las series no está

cointegradas), por lo tanto, las series sometidas a la investigación están cointegradas.

	Dependiente	tau-Statistic	Prob.	z-Statistic	Prob.
Series IPSA – NC	RIPSA	-17.75563	0.0000*	-363.0433	0.0000*
	RNC	-22.82137	0.0000*	-364.4210	0.0000*
Series IPSA – ND	RIPSA	-17.90064	0.0000*	-366.1700	0.0000*
	RND	-29.67279	0.0000*	-412.3730	0.0000*
Series IPSA – EMV_ID	RIPSA	-17.91572	0.0000*	-366.6895	0.0000*
	REMV_ID	-37.71246	0.0000*	-349.6729	0.0000*
Series IPSA - VIX	RIPSA	-17.21169	0.0000*	-330.1031	0.0000*
	RVIX	-21.43134	0.0000*	-324.2764	0.0000*
Series IPSA – SP500	RIPSA	-16.35909	0.0000*	-293.9311	0.0000*
Sentiment Index	RSP500_SENT_INDEX	-25.36255	0.0000*	-375.7939	0.0000*
Series IPSA – Fear and	RIPSA	-17.95390	0.0000*	-366.9154	0.0000*
Greed Index	RFG_INDEX	-20.71607	0.0000*	-359.2099	0.0000*
Series IPSA – VXEEM	RIPSA	-17.80350	0.0000*	-354.3376	0.0000*
	RVXEEM	-26.51269	0.0000*	-382.4906	0.0000*
Series IPSA – V2X	RIPSA	-17.55892	0.0000*	-339.2882	0.0000*
	RV2X	-18.65329	0.0000*	-287.2563	0.0000*
Series COLCAP -NC	RCOLCAP	-14.68702	0.0000*	-282.4901	0.0000*
	RNC	-23.36754	0.0000*	-363.7348	0.0000*
Series COLCAP – ND	RCOLCAP	-14.61417	0.0000*	-280.5979	0.0000*
	RND	-29.70174	0.0000*	-412.1155	0.0000*
Series COLCAP – EMV_ID	RND01	-28.45099	0.0000*	-403.0739	0.0000*
	REMV_ID	-34.61089	0.0000*	-342.1023	0.0000*
Series COLCAP - VIX	RCOLCAP	-13.63563	0.0000*	-247.0019	0.0000*
	RVIX	-20.67928	0.0000*	-330.0719	0.0000*
Series COLCAP – SP500	RCOLCAP	-14.18958	0.0000*	-257.6410	0.0000*
	Sentiment Index	RSP500_SENT_INDEX	-27.21457	0.0000*	-406.9376
Series COLCAP – Fear and Greed Index	RCOLCAP	-14.94410	0.0000*	-289.5748	0.0000*
	RFG_INDEX	-21.22760	0.0000*	-360.1444	0.0000*
Series COLCAP – VXEEM	RCOLCAP	-14.86331	0.0000*	-283.5489	0.0000*
	RVXEEM	-27.78303	0.0000*	-384.5023	0.0000*
Series COLCAP – V2X	RCOLCAP	-15.00675	0.0000*	-286.6462	0.0000*
	RV2X	-19.60866	0.0000*	-305.8646	0.0000*
Series SP BMV IPC – NC	RSP_BMV_IPC	-17.38294	0.0000*	-290.4529	0.0000*
	RNC	-23.53228	0.0000*	-362.2031	0.0000*
Series SP BMV IPC – ND	RSP_BMV_IPC	-17.18181	0.0000*	-290.9677	0.0000*
	RND	-29.29366	0.0000*	-415.1637	0.0000*
Series SP BMV IPC – EMV_ID	RSP_BMV_IPC	-17.22641	0.0000*	-290.2320	0.0000*
	REMV_ID	-37.65906	0.0000*	-349.2893	0.0000*
Series SP BMV IPC - VIX	RSP_BMV_IPC	-17.09848	0.0000*	-271.5919	0.0000*

	RVIX	-21.95822	0.0000*	-336.3935	0.0000*
Series SP BMV IPC –	RSP_BMV_IPC	-17.57697	0.0000*	-291.3690	0.0000*
SP500 Sentiment Index	RSP500_SENT_INDEX	-26.43068	0.0000*	-458.0757	0.0000*
Series SP BMV IPC –	RSP_BMV_IPC	-17.51333	0.0000*	-293.8159	0.0000*
Fear and Greed Index	RFG_INDEX	-21.03512	0.0000*	-361.0931	0.0000*
Series SP BMV IPC –	RSP_BMV_IPC	-17.50100	0.0000*	-288.3310	0.0000*
VXEEM	RVXEEM	-26.81231	0.0000*	-392.1104	0.0000*
Series SP BMV IPC –	RSP_BMV_IPC	-18.04079	0.0000*	-295.4849	0.0000*
V2X	RV2X	-19.69285	0.0000*	-316.7147	0.0000*
Series SP Perú Select –	RSP_PERU_SELECT	-19.23862	0.0000*	-385.2985	0.0000*
NC	RNC	-23.60869	0.0000*	-363.0143	0.0000*
Series SP Perú Select –	RSP_PERU_SELECT	-19.10865	0.0000*	-383.1608	0.0000*
ND	RND	-30.15959	0.0000*	-409.2934	0.0000*
Series SP Perú Select –	RSP_PERU_SELECT	-19.02068	0.0000*	-383.7188	0.0000*
EMV_ID	REMV_ID	-36.72174	0.0000*	-350.9245	0.0000*
Series SP Perú Select -	RSP_PERU_SELECT	-18.01073	0.0000*	-356.2473	0.0000*
VIX	RVIX	-20.28119	0.0000*	-343.0843	0.0000*
Series SP Perú Select –	RSP_PERU_SELECT	-17.26402	0.0000*	-332.9974	0.0000*
SP500 Sentiment Index	RSP500_SENT_INDEX	-23.08075	0.0000*	-427.2611	0.0000*
Series SP Perú Select –	RSP_PERU_SELECT	-18.99389	0.0000*	-382.9483	0.0000*
Fear and Greed Index	RFG_INDEX	-20.50795	0.0000*	-359.4612	0.0000*
Series SP Perú Select –	RSP_PERU_SELECT	-18.85199	0.0000*	-374.7667	0.0000*
VXEEM	RVXEEM	-25.51682	0.0000*	-393.4025	0.0000*
Series SP Perú Select –	RSP_PERU_SELECT	-18.41862	0.0000*	-366.0037	0.0000*
V2X	RV2X	-17.99183	0.0000*	-300.3465	0.0000*

Tabla 5.5: Resultados de prueba de cointegración realizada por medio de Eviews, fuente: realización propia.

*significancia estadística P-Value < 0,005

Es importante mencionar que el número de rezagos en la prueba se seleccionó con base en los criterios AIC (Akaike information criterion), SC (Schwarz information criterion) y HQ (Hannam-Quinn information criterion). Estos criterios se obtienen al aplicar el modelo VAR (Vectores Autorregresivos), y los resultados de causalidad en ambos sentidos de las variables se pueden ver en las tablas 5.6 a 5.9.

Causalidad (A -> Causa a -> B)	Chi-Sq	Df	P-Value
NC -> IPSA	13.95240	2	0.0009*
IPSA -> NC	5.303813	2	0.0705
ND -> IPSA	6.478373	8	0.5938
IPSA -> ND	13.49896	8	0.0958
EMV-ID -> IPSA	3.751584	4	0.4407

IPSA -> EMV-ID	3.169791	4	0.5298
VIX -> IPSA	28.06066	5	0.0000*
IPSA -> VIX	9.153803	5	0.1031
SP500 Twitter Sentiment INDEX -> IPSA	17.72074	2	0.0001*
IPSA -> SP500 Twitter Sentiment INDEX	2.122080	2	0.3461
FG_INDEX -> IPSA	17.70297	4	0.0014*
RIPSA -> FG_INDEX	10.43390	4	0.0337*
VXEEM -> IPSA	1.138354	2	0.5660
IPSA -> VXEEM	1.261828	2	0.5321
V2X -> IPSA	8.187621	2	0.0167*
IPSA -> V2X	0.142695	2	0.9311

Tabla 5.6: Causalidad de Granger Índice IPSA, Fuente: Elaboración propia. Software utilizado Stata.

*significancia estadística P-Value < 0,005

Causalidad (A -> Causa a -> B)	Chi-Sq	df	P-Value
NC -> COLCAP	10.89464	2	0.0043*
COLCAP -> NC	8.415027	2	0.0149*
ND -> COLCAP	9.421744	8	0.3080
COLCAP-> ND	10.45662	8	0.2344
EMV-ID -> COLCAP	2.707346	4	0.6079
COLCAP -> EMV-ID	3.740994	4	0.4422
VIX -> COLCAP	12.66420	2	0.0018*
COLCAP -> VIX	0.024157	2	0.9880
SP500 Twitter Sentiment INDEX -> COLCAP	15.24902	2	0.0005*
COLCAP -> SP500 Twitter Sentiment INDEX	15.26571	2	0.0005*
FG_INDEX -> COLCAP	20.83962	6	0.0020*
COLCAP -> FG_INDEX	7.630089	6	0.2665
VXEEM -> COLCAP	1.851446	2	0.3962
COLCAP -> VXEEM	2.887496	2	0.2360
V2X -> COLCAP	8.171258	3	0.0426*
COLCAP -> V2X	4.052349	3	0.2559

Tabla 5.7: Causalidad de Granger Índice COLCAP, Fuente: Elaboración propia. Software utilizado Stata.

*significancia estadística P-Value < 0,005

Causalidad (A -> Causa a -> B)	Chi-Sq	df	P-Value
NC -> SP BMV IPC	20.50192	7	0.0046*
SP BMV IPC -> NC	9.506311	7	0.2183
ND -> SP BMV IPC	16.06272	2	0.0003*

SP BMV IPC -> ND	4.169369	2	0.1243
EMV-ID -> SP BMV IPC	6.977791	4	0.1371
SP BMV IPC -> EMV-ID	6.298884	4	0.1779
VIX ->SP BMV IPC	9.741161	2	0.0077*
SP BMV IPC -> VIX	3.443100	2	0.1788
SP500 Twitter Sentiment INDEX -> SP BMV IPC	0.649397	2	0.7227
SP BMV IPC -> SP500 Twitter Sentiment INDEX	0.416571	2	0.8120
FG_INDEX -> SP BMV IPC	0.945377	2	0.6233
SP BMV IPC -> FG_INDEX	22.88574	2	0.0000*
VXEEM ->SP BMV IPC	2.532121	2	0.2819
SP BMV IPC -> VXEEM	1.756853	2	0.4154
V2X ->SP BMV IPC	8.761333	2	0.0125*
SP BMV IPC -> V2X	2.349837	2	0.3088

Tabla 5.8: Causalidad de Granger Índice SP BMV IPC, Fuente: Elaboración propia. Software utilizado Stata.

*significancia estadística P-Value < 0,005

Causalidad (A -> Causa a -> B)	Chi-Sq	df	P-Value
NC -> SP Perú Select	16.62984	10	0.0830
SP Perú Select -> NC	15.29144	10	0.1218
ND -> SP Perú Select	19.76141	14	0.1378
SP Perú Select -> ND	10.63490	14	0.7144
EMV-ID -> SP Perú Select	4.316810	4	0.3648
SP Perú Select -> EMV-ID	1.231780	4	0.8728
VIX ->SP Perú Select	1.673603	2	0.4331
SP Perú Select -> VIX	4.889351	2	0.0868
SP500 Twitter Sentiment INDEX -> SP Perú Select	5.402240	1	0.0201*
SP Perú Select -> SP500 Twitter Sentiment INDEX	0.045043	1	0.8319
FG_INDEX -> SP Perú Select	0.728153	2	0.6948
SP Perú Select -> FG_INDEX	23.03636	2	0.0000*
VXEEM ->SP Perú Select	0.412899	2	0.8135
SP Perú Select -> VXEEM	5.909185	2	0.0521
V2X -> SP Perú Select	6.030872	2	0.0490*
SP Perú Select -> V2X	0.832918	2	0.6594

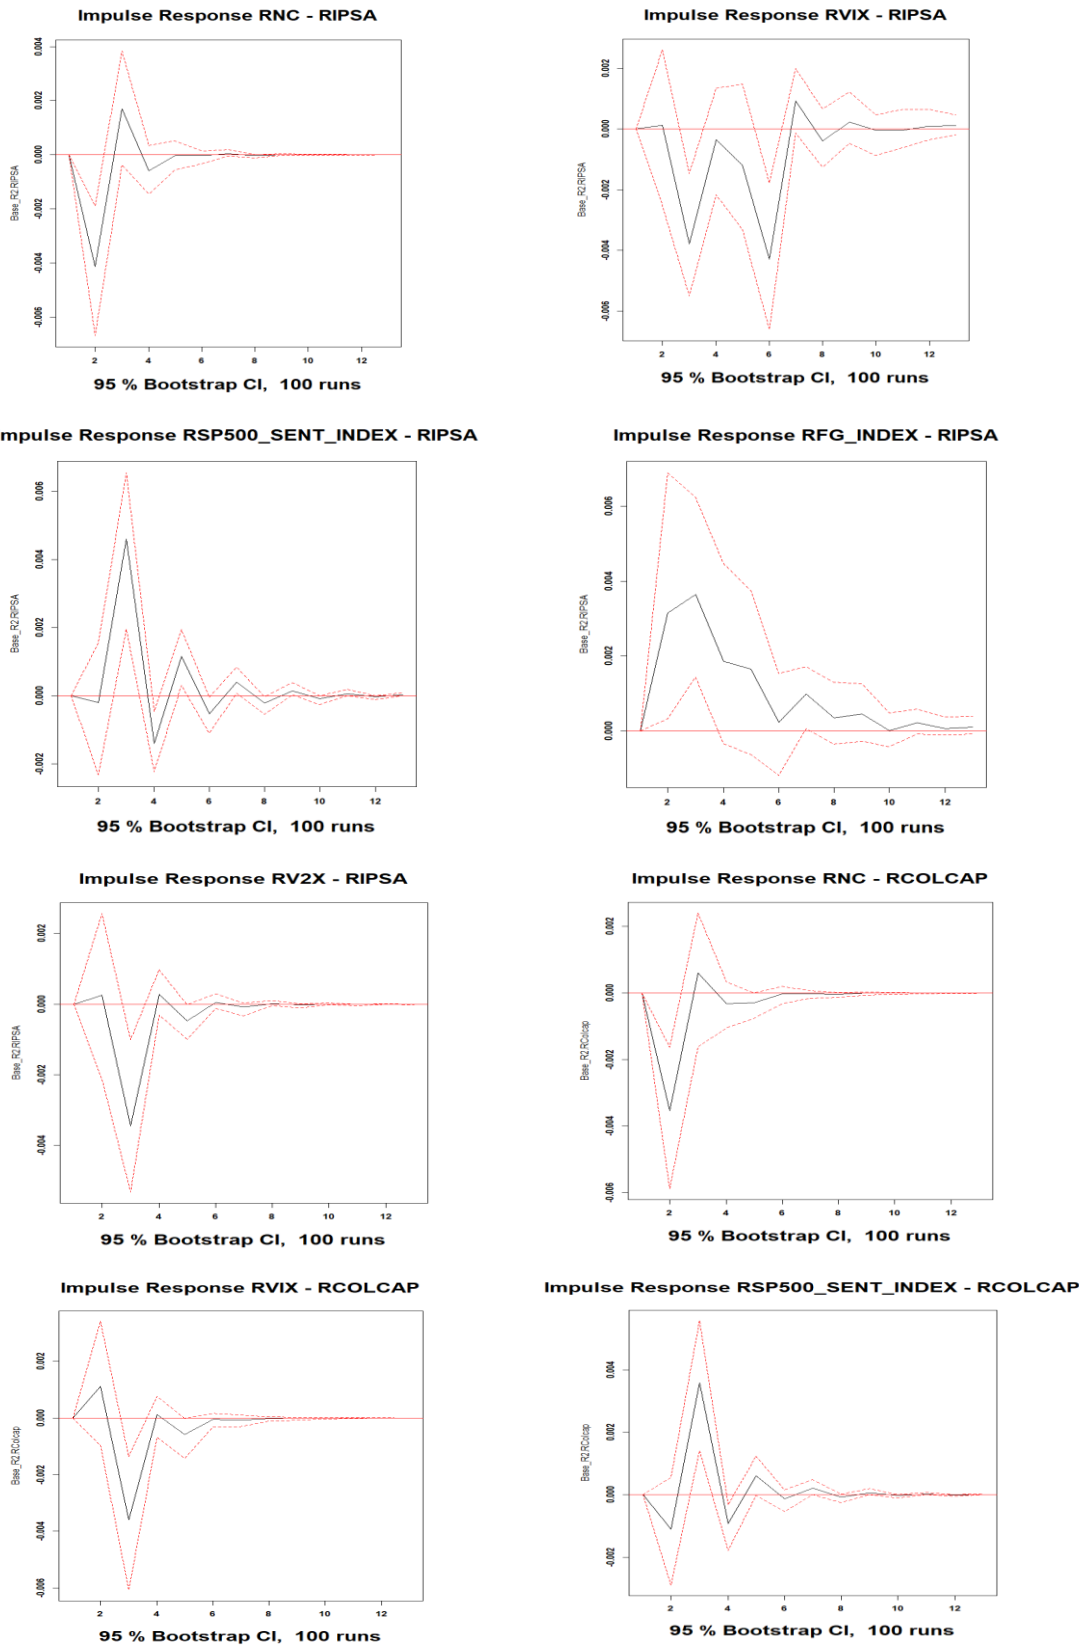
Tabla 5.9: Causalidad de Granger Índice SP Perú Select, Fuente: Elaboración propia. . Software utilizado Stata.

*significancia estadística P-Value < 0,005

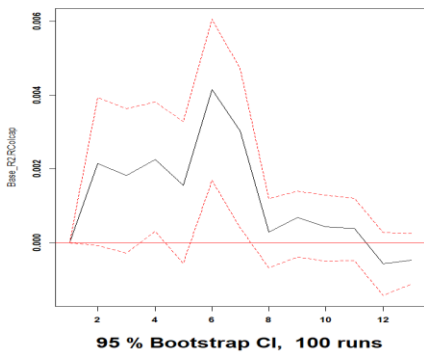
El propósito de la función de respuesta de impulso (IRF), es la descripción de la evolución que provoca una reacción en el modelo VAR. En la Figura 5.7 muestra

los gráficos de impulso respuesta acerca de las variables que causalidad con significancia estadística. Analizando el índice IPSA como respuesta de los factores que tiene causalidad, se puede concluir que el factor NC, obtiene una respuesta negativa en los primeros días, luego positiva y a partir del día 6 y 8 tiende el impulso a desaparecer, con respecto al factor VIX es más aleatorio tendiendo a estabilizar el shock de esta variable sobre el índice al día 12, con respecto al factor de sentimiento SP500 Twitter Sentiment, los impactos de esta variable sobre el índice son más bien positivos y desaparece entre el día 10 y 12. Al analizar el impulso del factor FG es más bien aleatorio, con un impulso negativo y se comienza a estabilizar a los 10 y 12 días y finalmente el índice responde negativamente en los cuatro primeros días al factor V2X, para luego estabilizarse a partir del día 8, desapareciendo en los días 10 y 12. Analizando las respuestas del índice COLCAP, con respecto al factor NC, comienza los primeros días con una respuesta negativa, luego al tercer día revierte la tendencia para desaparecer a partir del octavo día. El factor VIX obtiene como respuesta positiva los primeros días, luego al tercer día revierte la caída y desaparece el efecto a partir del día 9, revisando el factor de sentimiento SP500 Twitter Sentiment, al inicio tiene una respuesta negativa, pero al día siguiente revierte la tendencia a positiva, luego en los días siguientes repite el patrón, para luego desaparecer a partir del día 9. Con respecto al factor FG, tiene una respuesta más bien positiva en los 12 días, no logrando la estabilización, finalmente el factor V2X obtiene una respuesta negativa los primeros días, desapareciendo entre el día 10 y 12. Revisando las respuestas del índice SP BMV IPC, el factor NC obtiene como respuesta del índice negativamente en el período y no se estabiliza en los 12 días, con respecto al factor ND, obtiene una respuesta muy negativa en los dos primeros días, revirtiendo la caída positivamente el día 4, y desaparece el efecto de impulso posterior al día 10. Al revisar a los factores VIX y V2X tiene una respuesta negativa del índice al principio, desapareciendo el efecto al día 9 en adelante. Finalmente, las respuestas que obtiene el índice SP Perú Select con respecto al factor SP500 Twitter Sentiment tiene una caída pronunciada los dos primeros días, para luego desaparecer en el día 6 en adelante, con respecto al índice V2X responde positivamente los primeros días, para luego revertir el impulso y desaparecer a partir del día 9.


Figura 5.7: Impulso respuesta entre índices y variables, Fuente: Elaboración propia. Software utilizado Rstudio.




Impulse Response RFG_INDEX - RCOLCAP




Impulse Response RV2X - RCOLCAP




Impulse Response RNC - RSP_BMV_IPC




Impulse Response RND - RSP_BMV_IPC




Impulse Response RVIX - RSP_BMV_IPC




Impulse Response RV2X - RSP_BMV_IPC



Impulse Response RSP500_SENT_INDEX - RSP_Peru_Select



Impulse Response RV2X - RSP_Peru_Select



5.6.-Conclusión del capítulo

Los factores de riesgo que se utilizan en el estudio tanto para obtener el sentimiento de los inversionistas, como lo son de volatilidad o los construidos a partir de datos del COVID-19, son sometidos a análisis de su causalidad en los índices que componen el MILA, este análisis cobra real importancia para ser utilizados en trabajos posteriores en estos mercados, incorporándolos como factores de riesgo en los modelos de valoración de activos, con el objetivo en que los modelos de valoración, logren tener un mejor rendimiento en la fijación de precios y pronósticos.

Obtener un mejor rendimiento de los modelos, es fundamental para poder anticipar el proceso de toma de decisiones ante un periodo de mucha incertidumbre. Entendiendo que este fenómeno de crisis sanitaria se prolongará en el tiempo al existir nuevas variantes del virus o la aparición de una nueva emergencia sanitaria que provoquen una pandemia similar. Este estudio puede ser aplicado a otras contingencias que generen mayor inestabilidad en estos mercados, identificando variables e indicadores que puedan explicar de mejor la volatilidad en el mercado de valores, permitiendo prevenir grandes pérdidas en portafolios o fondos bursátiles.

La pretensión del trabajo es aportar una ligazón entre los modelos de valoración de activos a través del análisis lógico-matemático y las denominadas finanzas conductuales, en el contexto de los mercados latinos, tratando de levantar el supuesto de aversión al riesgo de los agentes del mercado. Existen investigaciones que indican que es necesario para que el mercado sea más eficiente agregar seis indicadores de comportamiento (cobertura mediática, noticias falsas, índices de pánico, sentimiento, exageración mediática e infodemia) frente a una crisis, como lo es la pandemia del COVID-19, denominándolo índice de “sentimiento febril”. Este índice aplicado en economías desarrolladas encuentra que es útil para anticipar políticas públicas que ayuden a mitigar los efectos de la pandemia en el mercado de valores. (Huynh, Foglia, Nasir, & Angelini, 2021)

Hoy en día con el avance tecnológico es posible capturar el sentimiento que mueve a los inversionistas en situaciones de crisis, una prueba de ello es la utilización de comentarios en las redes sociales, acerca del mercado o de una empresa en particular que se cotice en bolsa de valores. Existen estudios recientes que comprueban la incorporación de mensajes en redes sociales como Twitter,

utilizando herramientas de machine Learning, para clasificar los sentimientos tanto positivos y negativos (positivos reducen la volatilidad y negativos aumentan la volatilidad) en un mercado en particular, concluyendo que estas variables exógenas al mercado ayudan significativamente a la predicción de los retornos, en periodo de crisis como la del COVID-19. (Pradyot & Ritanjali, 2023) (Emre, Buket Kirci, Cevik, & Sel, 2022).

Se obtiene que los datos no se distribuyen normalmente, son estacionarios, y existe cointegración de las series, para luego aplicar la prueba de causalidad de Granger, observando además que los impulsos de estos nuevos factores hacia los índices de las bolsas sometidas a análisis afectan negativamente a partir los primeros días de la crisis.

Se obtiene como hallazgo que los índices de volatilidad tanto VIX como V2X, presentan significancia estadística y causalidad con todos los índices del MILA al igual que factor de miedo y codicia en el mercado de las criptomonedas. El índice de sentimientos de los inversores capturados por la red social Twitter, presenta causalidad con significancia estadística en los índices de las bolsas de valores de Chile, Colombia y Perú. En el caso de México existe un estudio anterior que encuentra que las noticias del COVID-19, no genera episodios de alta volatilidad en la bolsa de valores de México (BMV IPC), identificando que el aumento de volatilidad viene desde el contagio de mercados estadounidenses. (De la Torre-Torres, 2020).

Con respecto al factor de riesgo de nuevos casos de COVID-19 a nivel mundial, tiene causalidad y significancia estadística para los índices de los mercados de Chile, Colombia y México, en el caso de México es el único mercado donde obtiene causalidad el factor construido a partir de las muertes diarias a causa del COVID-19. Este resultado implica que la información rezagada diaria de los indicadores que capturan volatilidad o temor de los inversionistas, ayudan a la valoración y predicción de los activos en los mercados analizados, en situación de crisis sanitaria, al menos en el corto plazo.

En resumen, los índices VIX, V2X, SP&500 Twitter Sentiment, y Fear and Greed y el índice creado a partir de los nuevos casos de COVID-19 a nivel mundial, presentan información relevante en estos mercados y pueden ser utilizados como factores de riesgo en los modelos de valoración de activos. Existen investigaciones en países emergentes (sudeste asiático) que encuentran como hallazgo que los nuevos casos de Covid, generan mayor volatilidad en el

mercado de valores (Sadiq, Hsu, Zhang, & Chien, 2021). Como también investigaciones en países de mayor desarrollo sugieren la utilización de índices de volatilidad y de sentimiento en época de crisis pandémica (De la Torre-Torres, Bollain-Parra, & Durán-Sánchez, 2022). Para futuras investigaciones es importante la revisión de estos factores agregándolos en los modelos de valoración, para comprobar su contribución en información relevante de riesgo en tiempo de crisis sanitaria, con el objetivo de obtener información temprana que sirva para la toma de decisiones, mitigando las pérdidas de los fondos de inversión, y manteniendo la eficiencia en los mercados de valores.

Capítulo 6 : Modelo de Fama Cahart
Extendido con factores de
comportamiento y volatilidad como
propuesta en tiempos de crisis,
aplicado en los índices que componen
el MILA.

6.1.-Resumen del capítulo

En la búsqueda de variables que puedan dar cuenta del sentir de los inversionistas en un momento determinado, en este caso, en crisis sanitaria, se encarga este capítulo de validar los factores de riesgo exógenos, que permitan entregar información relevante para los índices bursátiles de los países que componen el MILA. En términos simples es el ejercicio de levantar el supuesto de racionalidad de los agentes del mercado, el cual es la aversión al riesgo, agregando factores que pueden inferir el comportamiento de los participantes en tiempo de incertidumbre, en los índices de los países que componen el MILA (Mercado Integrado Latino Americano).

Este trabajo agrega al modelo de Fama Cahart de cuatro factores, variables acerca de la volatilidad, de sentimiento en la red social Twitter y el índice de miedo y codicia, creado a partir de la criptomoneda Bitcoin, además de un factor construido a partir de los nuevos casos confirmados de COVID-19 a nivel mundial.

Se consideran datos diarios en un periodo que considera dos crisis mundiales como lo es la pandemia y la guerra de Rusia con Ucrania, comprendiendo el periodo desde diciembre de 2019 a marzo de 2022.

La metodología que se utilizará es la siguiente: Hausman y estadístico F es una prueba que se utiliza para evaluar la capacidad explicativa que tiene un grupo de variables independientes sobre la variación de la variable dependiente del modelo sometido a evaluación, y también se aplicara el estimador de máxima verosimilitud Log-verosimilitud. Este modelo Logit estima la probabilidad de impacto de las variables explicativas sobre la variable dependiente que en este caso es de respuesta cualitativa.

Como resultado se obtiene que el modelo extendido de Fama Cahart de cuatro factores, logra una mayor explicación de los retornos de los índices en el periodo de crisis considerado en la investigación, sin embargo, con respecto a los coeficientes que se agregan al modelo acerca del temor de los inversionistas, sólo el factor de sentimiento SP500 Twitter Sentiment y el de volatilidad en la eurozona V2X, son relevantes en los índices de Chile, México y Perú.

6.2.-Introducción

Cuando se utilizan variables propias del mercado en la determinación del valor de un activo, es práctico, ya que son fácilmente modelados por medio de ecuaciones matemáticas, pero se deja de lado aspectos de comportamiento de los inversionistas, estableciendo como supuesto el actuar de las personas, como individuos que carecen de preferencia por el riesgo en sus inversiones. Por otro lado, se encuentra el aspecto conductual de las personas frente al riesgo, que aportan las ciencias de la sociología y psicología. El actuar de las personas afecta a las decisiones de sus inversiones y forma parte de lo que se conoce como finanzas conductuales, indicando que el supuesto de aversión al riesgo de los agentes provoca la pérdida de información relevante al momento de valorar los activos.

Los modelos clásicos que utilizan los administradores de carteras en el mundo han tenido varias controversias en sus resultados en varios mercados que se han aplicado, tanto en mercados desarrollados y últimamente en mercados emergentes (Bai y Green 2020) (Elbannan 2015) (Harvey 1995) (Roll, Richard, 1977). Explorar en cómo aplicar el comportamiento de los agentes del mercado, como parte de los modelos matemáticos ha resultado una tarea necesaria y además relevante en el presente y futuro de las finanzas corporativas, más con la oportunidad de nuevas formas de obtener datos e información por medio de la tecnología de la información y su desarrollo actual, hoy en día es más fácil y menos costoso para acceder a estos datos.

Si bien es cierto han existido muchas modificaciones a los modelos de valoración de activos, debido a sus debilidades o incompletitud, es esta razón que motiva indagar en variables de comportamiento y de sentimiento en el mercado latinoamericano. En este sentido existen diversos estudios en otros mercados que indican que el incorporar nuevas variables que agreguen valor explicativo al modelo, estos factores aportan en forma significativa al desempeño del modelo de valoración. (Apergis & Rehman, 2018) (Shefrin y Statman 1994) (Chandra y Thenmozhi 2017) (Shiller 2003)

El modelamiento matemático basado en el supuesto que los inversionistas son aversos al riesgo, y con este actuar contribuye a que los mercados tengan eficiencia, en donde no exista espacio para ganancias o pérdidas anormales, contribuyendo al juego limpio en el mercado de valores (Fama, Eugene, 1970), deja en una constante la problemática de que los inversionistas racionales están

limitados; donde sus decisiones son influenciadas por sus emociones, sesgos cognitivos y de comportamiento, de acuerdo con su acervo cultural y social. Estos aspectos no se pueden disociar de sus heurísticas para la toma de decisión. Esto último ha generado una gran discusión de la teoría de eficiencia basada en la racionalidad y la aversión al riesgo de los agentes del mercado, por una parte, si los agentes fueran racionales o aversos al riesgo, no existirían crisis como las que se han vivido en el mercado y de acuerdo con ambos conceptos tampoco se hubiesen experimentado burbujas especulativas financieras, como han ocurrido en la historia reciente.

A finales de los setenta se introdujeron investigaciones que dan cuenta del comportamiento de las personas bajo situaciones de incertidumbre, donde resultan en varios casos, totalmente irracional e inconsistentes en la toma de decisiones económicas, además de plantear que los inversores asumen las pérdidas y las ganancias de forma diferente, por lo tanto, las personas toman sus decisiones basadas en la percepción de las ganancias más que lo que perciben de las pérdidas, donde el inversor optara por las ganancias en lugar de las pérdidas, si tiene que elegir entre las dos opciones, de ahí se deriva la teoría de aversión a las pérdidas ([Kahneman y Tversky 1979](#)).

Desde las finanzas conductuales se abre un espacio para poder explicar el comportamiento de los mercados y poder llegar a la eficiencia ([Sewell, 2007](#)).

También estudios demuestran como las personas resuelven los problemas de forma más sencilla y menos compleja, esto es fundamental para comprender los errores en las elecciones que realizan las personas. En este proceso de escoger se dan tres comportamientos que realizan las personas en situaciones de incertidumbre, en primer lugar, la representatividad, donde frente a una acción de una empresa que se considera sólida o consolidada en el mercado, baja su precio, se tiende a comprar, en el sentido de comprar barato para posteriormente se pueda vender caro, sin embargo, si un rendimiento fue positivo en el pasado, no tiene por qué repetirse en el futuro. Otro actuar de los inversionistas está dado por la disponibilidad donde las personas prefieren elegir inversiones que estén representadas por empresas que den mayor confianza, por lo tanto, eligen inversiones conocidas ante inversiones de empresas nuevas, aunque sean mucho más ventajosas o rentables, y por último, el comportamiento de anclaje y ajuste, donde las personas no conocen el valor real inicial, en la toma de decisiones, por lo que cualquier información lo toman como base para decidir, en consecuencia, este comportamiento es perjudicial, porque se elimina el valor fundamental y se

toma la decisión desde una realidad absoluta, donde en la mayoría de las veces las estimaciones nunca o casi nunca son acertadas (Tversky y Kahneman 1982).

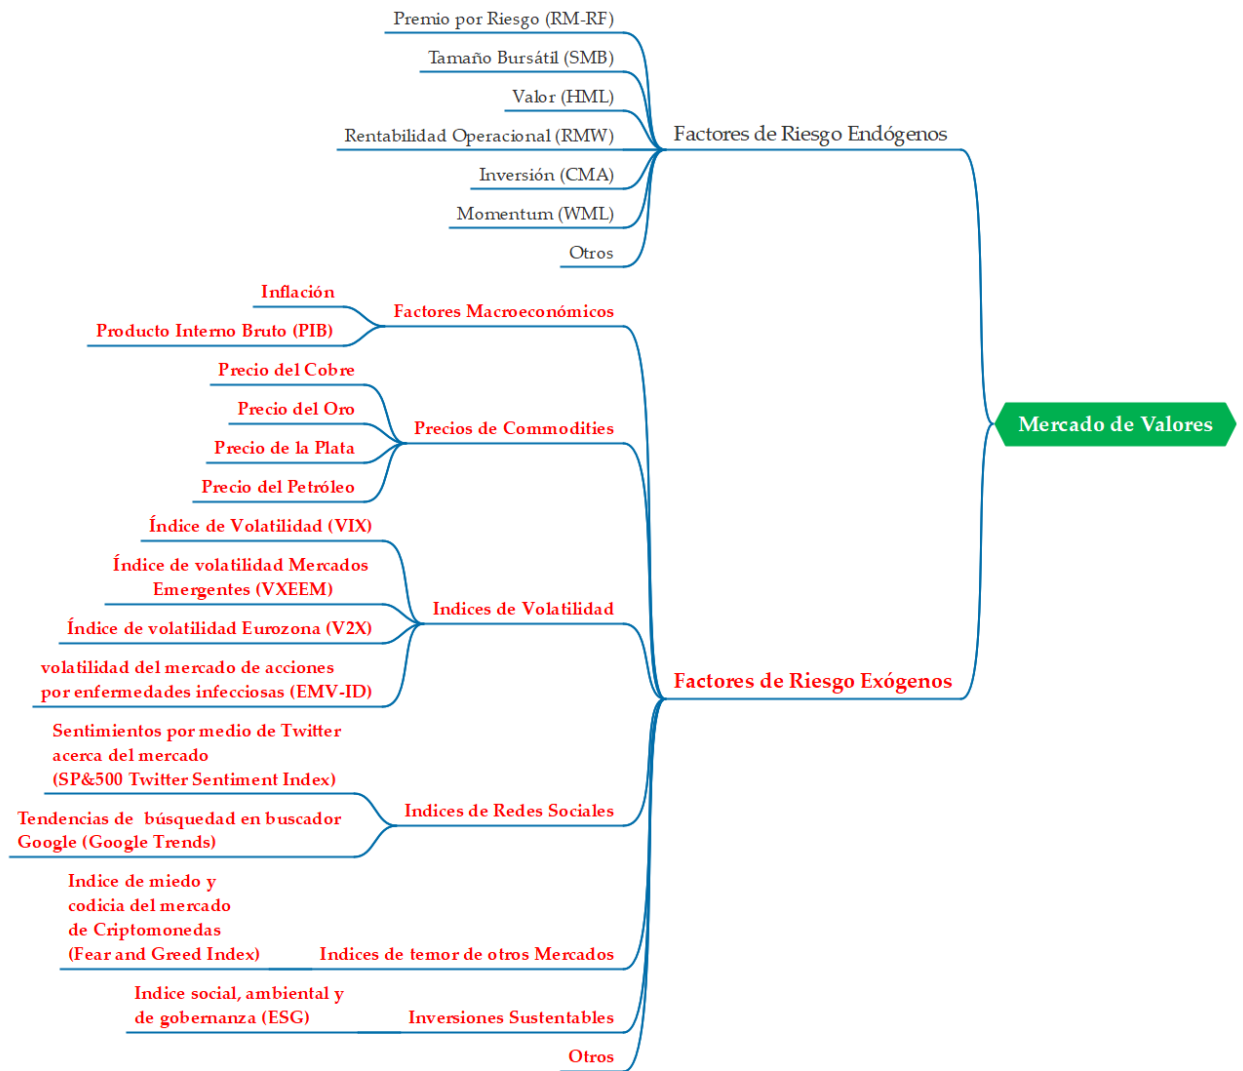
Es importante recalcar que esta investigación se centra en buscar factores exógenos que permitan entregar información del comportamiento de los agentes del mercado, agregándolos a un modelo de valoración de activos derivados del modelo CAPM de Fama y French.

6.3.-Revisión de la literatura

En la figura 6.1, se visualiza un esquema de factores de riesgo, desde los más tradicionales, como aquellos que se han propuesto los autores originales del modelo de valoración CAPM y que se obtiene a partir de los datos propios de los activos que se desean valorar que se denominan endógenos.(Sharpe1963) (Lintner, 1965; Lintner, 1965) (Fama y French 1995) (Fama & French, 2015) (Carhart 1997). Además, se muestran otros factores que han irrumpido en investigaciones a lo largo del tiempo, tratando de explicar los rendimientos de los retornos en distintos mercados del mundo, los que se denominan como exógenos al modelo de valoración, que pueden tener información relevante y mejoran la fijación de precios.

En la tabla 6.1, se muestran estudios que utilizaron factores de riesgos distintos a los tradicionales.

Figura 6.1: Mapa Mental de algunos factores de riesgo, endógenos y exógenos que han sido explorados en investigaciones en búsqueda de mejorar el modelo de fijación de precios de los activos, Fuente: Elaboración Propia.



Revisión de la literatura acerca de los factores de riesgo que provienen desde la macroeconomía:

Un estudio realizado por (Singh 2008), El análisis de componentes principales APT (Arbitrage Pricing Theory, modelo multifactorial) fue capaz de explicar los datos de corte transversal de rendimientos mucho mejor que el CAPM, los factores de este modelo no tenían un impacto económico. Los factores macroeconómicos (de mejor desempeño el tipo de cambio) utilizados en este estudio fueron capaces de explicar los rendimientos marginalmente mejor que sólo el riesgo sistemático beta. Si bien esto confirma que el riesgo es

multidimensional y que no debemos depender de Sólo beta, se requiere más investigación para identificar otras variables que pueden ayudar a explicar los retornos en la bolsa de valores de Bombay entre 1991 y 2002. En la misma línea de investigación sobre variables macroeconómicas (Azam 2022) realizan una investigación con el mercado de valores de Pakistán. Utilizan el modelo de valoración CAPM utilizando el método de mínimos cuadrados ordinarios, aplicado sobre series de tiempo. Utilizando datos mensuales de enero de 2002 a diciembre de 2020 y una muestra completa de 522 empresas financieras y no financieras que cotizan en PSX. Los resultados obtenidos son los siguientes: una relación positiva y estadísticamente significativa entre los rendimientos del mercado y el crecimiento del PIB. Otra investigación de (Vassalou 2003) utiliza la metodología de validación del modelo CAPM de tres factores donde incluye el factor de riesgo del PIB (Producto Interno Bruto), de Fama Macbeth, con datos del mercado de valores de Estados Unidos, obteniendo como conclusión que el crecimiento futuro del PIB es mejor predictor que los factores de tamaño (SMB) y valor (HML), utilizando 25 portafolios con activos del mercado de Estados Unidos. (Sato, Miyazaki y Mawaribuchi 2011) Investigan en el mercado de valores de Japón en el periodo deflacionario de la economía japonesa que abarca entre 2001 a 2010. Esta investigación agrega el factor de riesgo de inflación al modelo de Fama French de tres factores. El resultado empírico para la estrategia de cartera Inflación-CAPM reporta que el desempeño (oportunidad de la estrategia de cartera, rentabilidad acumulada, tasa de éxito, rentabilidad trimestral media y ratio de Sharpe) de nuestra estrategia es superior a la estrategia alfa habitual (estrategia de cartera CAPM) del modelo de Fama French de tres factores. Otra investigación que incorpora factores de riesgo desde la macroeconomía realizado por (Javid y Ahmad 2012) el análisis de este estudio explora un conjunto de variables macroeconómicas junto con la rentabilidad del mercado como las fuentes sistemáticas de riesgos que explican las variaciones en los rendimientos esperados de las acciones para 49 acciones negociadas en la Bolsa de Valores de Karachi (Pakistán) para el período 1993-2004. Se realiza la prueba de CAPM multifactorial condicional especificando la varianza condicional como un proceso GARCH (1,1). Los resultados que obtiene es que algunas variables económicas (crecimiento del consumo, riesgo de inflación, riesgo cambiario, riesgo del precio del petróleo) resultan ser importantes para explicar los rendimientos esperados de las acciones en el período de 1993 a 2004. (Cappiello y Guéné 2005) En este artículo, se estima un modelo un ICAPM (Intertemporal Capital Asset Pricing Model), para Francia y Alemania desde

mediados de la década de 1980 hasta junio de 2003. Se utiliza un solo un factor para el modelo CAPM. Obtienen como resultado que los rendimientos de acciones, bonos a corto y largo plazo, en el caso de los bonos de corto y largo plazo, que el premio por riesgo de inflación es superior al premio de riesgo de mercado (RM-RF), y el premio por riesgo de inflación de los bonos de largo plazo, es más relevante en el mercado que el premio por riesgo de los bonos de corto plazo. Finalmente, como conclusión obtienen que este riesgo de inflación es relevante en la explicación del rendimiento de las acciones en estos mercados, posterior a 1999, cuando se cumple la etapa tres de la unión europea. Otro estudio en ese mismo sentido ([Garnia, y otros 2021](#)), un estudio realizado en indonesia, un estudio da cuenta que el precio de las acciones se ve afectado por varias variables macroeconómicas, como índice de mercado global, la oferta monetaria, la tasa de interés, tasa de inflación y el precio del petróleo, en el período 2009 hasta 2019, donde el índice de mercado global, la tasa de interés y la inflación tiene un efecto positivo sobre los activos y el precio del petróleo tiene un efecto negativo, sin embargo, la oferta monetaria, tiene un efecto insignificante. ([Boyd, Hu y Jagannathan 2005](#)), realizan un estudio interesante, con datos del índice SP&500, acerca de las noticias acerca del desempleo afectan al mercado, estos investigadores observan que, en promedio, los precios de las acciones suben cuando existen noticias sobre el aumento del empleo. Concluyendo que un anuncio de incremento del empleo es una buena noticia para las acciones durante las expansiones económicas y malas noticias durante el aumento de desempleo, en las contracciones económicas.

Revisión de la literatura acerca de los factores de riesgo que provienen de la volatilidad (índice VIX):

([Arisoya, Altay-Salih, & Akdeniz, 2015](#)), realizan una investigación donde extienden el modelo CAPM con el índice VIX (Chicago Board Options Exchange Market Volatility Index), proponiendo el modelo V-CAPM (modelo de valoración de corto plazo, definido con los resultados de la investigación), donde se somete a prueba con el test de Fama Macbeth, obteniendo como resultado que el factor con datos del índice VIX, se comporta estadísticamente significativo durante el periodo en estudio. ([Bekaert y Hoerova 2014](#)), realizan un estudio que analiza crisis económicas con el mercado de valores (SP&500), buscando un factor para explicar la mayor volatilidad del mercado, agregan al modelo el índice VIX, donde encuentran que tiene poder predictivo de los rendimientos de acciones en el mercado. Una investigación de ([Hitz, Mustafi y Zimmermann](#)

2022), se plantean la pregunta de que si los proxies basados en volatilidad aportan una mejor valoración de las acciones que otro factores de riesgo, por ejemplo que provienen de la macroeconomía, para llevar a cabo la investigación, comparan los resultados de un modelo de valoración de activos extendido con el índice de incertidumbre macroeconómica (MU), y tres modelos con proxies de índices VIX, un factor basado en EGARCH (a corto plazo) y un proxy que mide la incertidumbre de la política monetaria. Aplicada a conformación de carteras con activos de la bolsa de valores de Estados Unidos. Obteniendo como conclusión que el factor de volatilidad VIX, es estadísticamente significativo en los modelos sometidos a prueba. A todos los estudios favorables de la utilización del índice de volatilidad VIX, también ha investigaciones que encuentran anomalías de este índice de volatilidad tal como la investigación de (Kownatzki 2016), sugieren que el VIX exagera constantemente la volatilidad real en aproximadamente 430 puntos básicos en todos los períodos de tiempo, desde diferencias de 1 día hasta 60 días. Las expectativas de riesgo de los inversores, derivadas de los precios de las opciones, pueden estar infladas. Curiosamente, durante los períodos de tiempo más críticos, como caídas o crisis del mercado, el VIX no cumple su promesa. En medio de la crisis financiera de 2008, el VIX subestima la volatilidad realizada en alrededor de 180 puntos básicos en promedio. El tiempo también juega un papel importante. 26 de los 40 peores días de subestimación de la volatilidad real ocurren entre septiembre y diciembre de 2008. Además, durante el período de dos semanas inmediatamente posterior a la quiebra de Lehman Brothers, el VIX tuvo algunos de sus peores momentos en términos de subestimación del riesgo de mercado real.

Revisión de la literatura acerca de los factores de riesgo que provienen desde las redes sociales:

(Chen, y otros 2019), realizan una investigación acerca de cómo el sentimiento depositado en una red social financiera del mercado financiero de China, puede mejorar el rendimiento del modelo de valoración, utilizan datos del Shanghai Composite Index y comentarios desde Eastmoney (red social de la comunidad financiera en China), clasificando los comentarios en positivos y negativos con respecto al mercado. La metodología que utilizan algoritmos de machine learning. Encuentran que el sentimiento derivado de Eastmoney, una red social de la comunidad financiera en China mejora el rendimiento del modelo de valoración, al clasificar los sentimientos en positivos y negativos. (Kolasani y Assaf 2020), realizan una investigación que busca predecir el movimiento futuro

del mercado de valores de los Estados Unidos analizando el sentimiento de las publicaciones de Twitter relacionadas con el mercado de valores y probando dos métodos para llevar a cabo esta tarea. Para llevar a cabo este trabajo utilizan el precio de la acción de Apple (APPL), utilizando un modelo de árbol de regresiones y una red neuronal, para predecir el comportamiento del precio de la acción, de acuerdo a los sentimientos clasificados en positivos y negativos acerca de la empresa y/o acción o empresas del sector en la red social Twitter, obtienen como resultado que por medio de mensajes de Twitter sobre la acción de Apple (APPL), las redes neuronales funcionan sustancialmente mejor que los modelos tradicionales para la predicción del precio del activo. Bajo el uso de esta red social de comentarios más bien de política o mercados financieros (Agarwal, Kumar y Goel 2021), realizan un estudio de causalidad (causalidad de Granger) de los comentarios de la red social Twitter y el índice Nifty50 (India), encuentran que los sentimientos expresados en Twitter acerca del mercado tienen un efecto significativo con las acciones financieras y bancarias de la bolsa de valores. En esta misma línea (Mendoza, García-Medina y Nuñez 2021) de utilizar sentimientos de Twitter, donde procesan entre 2013 y 2018, 200.500 tweet, por medio de un algoritmo de minería de texto, clasificándolas diariamente según la empresa mencionada y elegida para el estudio, construyendo un índice de sentimiento desde la red social, donde obtienen como hallazgo que esta información es útil para determinar los precios de las acciones de las empresas estudiadas. (Wu, y otros 2017) realizan investigación en China, por medio de redes sociales del país, algunas especializadas en finanzas y economía, encuentran que el efecto del factor social (redes sociales), en que la volatilidad es capturada por este factor y es importante para predecir la volatilidad de las acciones a corto plazo, pero disminuye en mediano a largo plazo.

Revisión de la literatura acerca de los factores de riesgo que provienen desde las noticias:

(Li 2021) realizan un estudio de modelado de pronóstico a corto plazo de acciones, basado en la búsqueda del sentir del inversor, buscando su influencia o información que provee a la valoración de los activos, proponiendo utilizar las noticias de CNN para extraer información emocional profunda para reemplazar el supuesto de comportamiento en el mercado, para mejorar el desempeño predictivo del modelo de valoración, mediante la utilización de Deep Learning, aplicado en el mercado de Shanghái. Encontrando información útil y relevante para mejorar la predicción de los activos en el mercado.

Revisión de la literatura acerca de los factores de riesgo que provienen desde las búsquedas es Google y del miedo desde las criptomonedas, e índice de responsabilidad social de las empresas:

Un estudio de (Akarsu y Suer 2021) que analiza la atención de los inversionistas a nivel internacional y evaluar el impacto de la rentabilidad de las acciones en 31 países. Buscando esta atención de los inversionistas por medio de la búsqueda de las empresas o nombre de las acciones en el motor de búsquedas Google, extrayendo los datos desde la plataforma de Google Trends. encuentran que el impacto de la atención de los inversores sobre la rentabilidad de las acciones no es uniforme en todo el mundo. La dirección y la importancia del impacto varían de un país a otro. Podría decirse que el efecto de la atención de los inversores podría ser más pronunciado en poblaciones pequeñas. Por lo tanto, futuro La investigación debe examinar el impacto de la atención de los inversores utilizando una muestra más grande que incluye acciones de pequeña capitalización. Otro estudio de (Burggraf, y otros 2020) que forma un factor de sentimientos de los inversores, utilizando un índice construido a partir patrones de búsquedas por medio de Google Trends (GSV: Google Search Volume), encuentran que el sentimiento de los inversores tiene fuerte poder predictivo sobre el precio del Bitcoin. (Güler 2021) mide el impacto del sentimiento de los inversores en los rendimientos de Bitcoin y la volatilidad condicional de la pandemia del COVID-19, empleando el modelo EGARCH, tienen como hallazgos que el sentimiento de los inversores tiene un impacto positivo en los rendimientos de Bitcoin y en su volatilidad en el período de pandemia. Este impacto puede ser atribuido al comportamiento a partir del miedo de pérdidas de los inversores especulativos e irracionales. (Li y Wang 2013) prueban en su investigación el índice de Fear and Greed (miedo y codicia), revisan la influencia en los fondos mutuos de Taiwán y el sentimiento de los inversores representado por el índice Fear and Greed como factor, encontrando que este índice afecta a los precios del fondo mutuo, especialmente en aspecto de comportamiento irracional impulsado por el miedo y la codicia. Y finalmente (Saiful y Koji 2020) investigaron acerca de las inversiones socialmente responsables (SRI), en el mercado de Japón, obtiene como hallazgo que, en la comparación de los fondos convencionales y fondos socialmente responsables, estos últimos fueron más resistentes a la incertidumbre, en torno a las recientes elecciones presidenciales de EE. UU., mientras que los fondos convencionales fueron más sensibles durante el referéndum del Brexit.

Revisando el supuesto de racionalidad de los agentes económicos.

El principio de la racionalidad de los agentes económicos, se originó a partir de la teoría de la utilidad esperada ([Von Neumann & Morgenstern, 1947](#)), según esta teoría los inversionistas son completamente racionales, tienen la capacidad de manejar opciones de inversión complejas, son reacios al riesgo y además tienen la necesidad de maximizar su riqueza, en otras palabras los inversores seleccionan la cartera que mejora a su utilidad esperada, medida en términos de rendimiento esperado y al mismo tiempo disminuyen los riesgos y pérdidas. Esta teoría es la que se pone en cuestión desde hace unas cuatro décadas en la ciencia financiera, donde los aspectos de racionalidad, anomalías del mercado y conductas de los agentes cobra validez en las crisis que evidencian los mercados. Se puede citar la paradoja de Allais, que tempranamente surge como contraste a la teoría de utilidad esperada. Esta paradoja da cuenta de cómo los individuos piensan y toman decisiones de forma inconsciente. Se establece este aspecto a través de hechos empíricamente demostrados, los que se muestra cómo la teoría de la utilidad esperada, en numerosas ocasiones, no se cumple ([Allais 1953](#)).

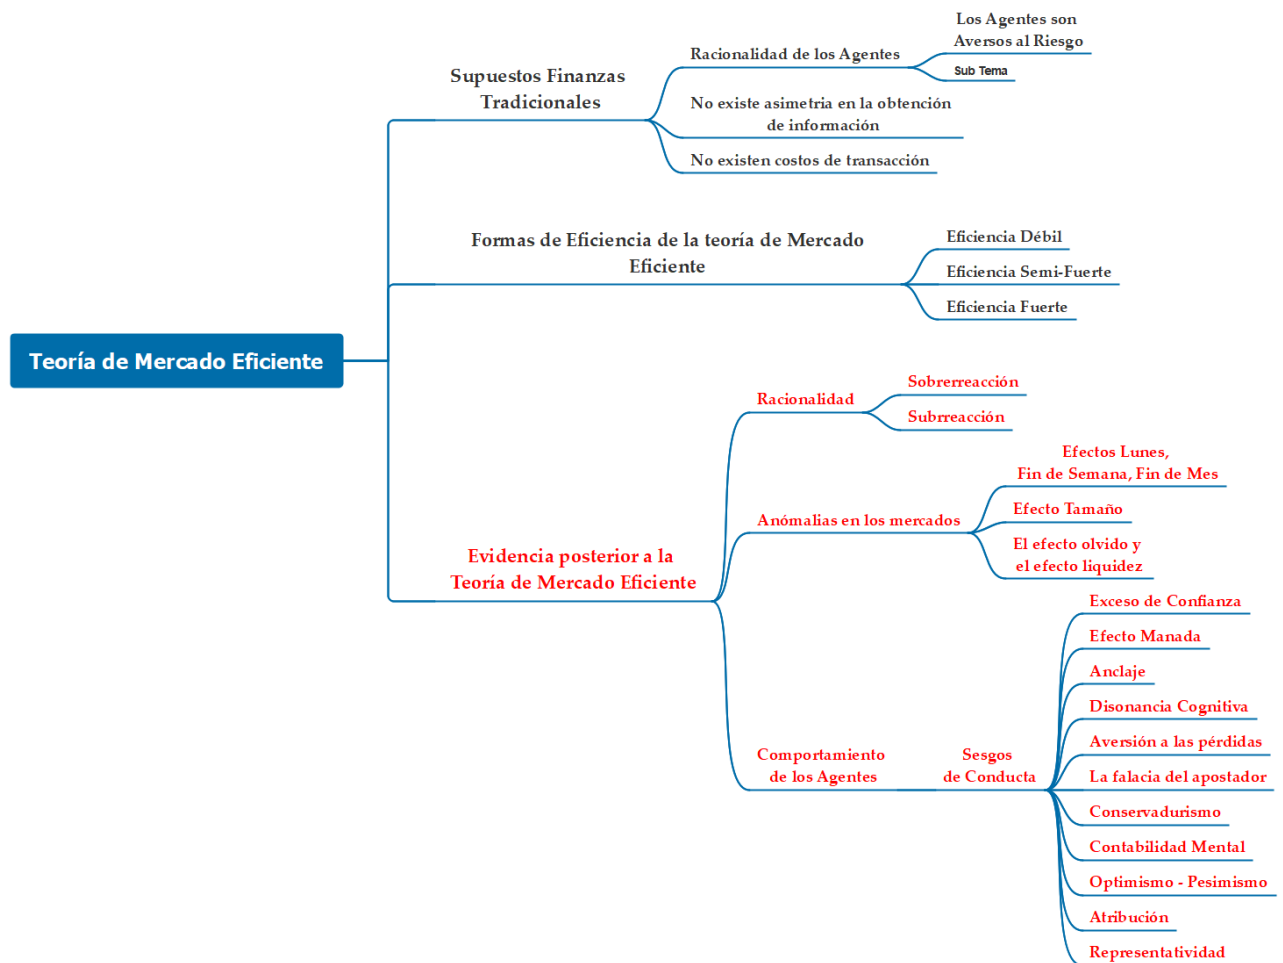
En situaciones emocionales que afectan a los inversionistas cuando toman decisiones, uno de ellos es el sesgo, donde se plantea que el ser humano no se mantiene consciente todo el tiempo, donde sus convicciones y experiencia anterior lo afectan en sus tomas de decisiones, en muchos casos este sesgo aporta a la ineficiencia de los mercados, otro elemento fundamental es la falacia del jugador donde frente a un activo que sube su precio en tres días seguidos, este espera que al cuarto día obtenga una caída, esto provoca que venda el activo antes que baje su valor, y por último el comportamiento de rebaño o manada, donde los movimientos de los inversores más grandes, son seguidos por los más pequeños, solo por considerar válidos sus movimientos, sin cuestionar racionalmente los movimientos que están realizando. ([Kudryavtsev, Cohen y Hon-Snir 2013](#)). ([Filiz, y otros 2018](#))([Cao, Nguyen y Tran 2021](#))([Hirshleifer 2001](#))

Es importante la inclusión de comportamientos más reales de los agentes del mercado, para lograr una mejor comprensión de las reacciones de las personas en tiempos de incertidumbre, este sentir de los agentes acerca del mercado, tomados en cuenta, van en dirección de beneficiar a los tomadores de decisiones ([Thaler 1999](#)).

En la figura 6.2, muestra los factores que son relevantes para entender la eficiencia de mercado y la mejor fijación de precios de las acciones, estos aspectos

se han recopilado a través de investigaciones, orientadas en la búsqueda de mejorar la valoración de los activos, en ese sentido esta investigación tiene el objetivo de colocar en el tema de inversiones, la conducta de las personas, que al final son las que toman las decisiones.

Figura 6.2: Mapa Mental de la teoría de mercados eficientes y evidencia de aspectos considerados como supuestos que son discutibles a través de la evidencia de investigaciones posteriores a la teoría, Fuente: Elaboración Propia.



6.4.-Metodología y datos

En el modelo multifactorial para revisar su rendimiento y pronóstico, utilizará las siguientes variables (tabla 6.2):

Variable	Descripción
IPSA	Índice de Precios Selectivo de Acciones. Mide las variaciones de precios de las empresas emisoras chilenas más grandes y líquidas listadas en la Bolsa de Santiago.
COLCAP	Índice bursátil de la Bolsa de Valores de Colombia. Refleja las variaciones de los precios de las 20 acciones más líquidas,

	donde el valor capitalización bursátil ajustada de cada compañía determina su participación dentro del índice.
S&P_BMV IPC	El S&P/BMV IPC (Índice De Precios y Cotizaciones) busca medir el desempeño de las acciones de mayor tamaño y liquidez listadas en la Bolsa Mexicana de Valores. Su objetivo es proporcionar un índice amplio, representativo, pero al mismo tiempo fácilmente replicable, que abarque el mercado bursátil mexicano.
S&P Perú Select Index	El S&P/BVL Perú Select Index busca medir el desempeño de las empresas de mayor tamaño y liquidez listadas en la Bolsa de Valores de Lima (BVL).
NC	Nuevos Casos de COVID-19 en el mundo.
VIX	Índice de Volatilidad mide la volatilidad de las opciones del mercado de Chicago (CBOE o Chicago Board Options Exchange) en el índice S&P500 (Standard & Poor's 500).
V2X	Índice de volatilidad (VIX), mide la volatilidad en la Eurozona
SP&500 Twitter Sentiment Index	El S&P 500® Twitter Sentiment Index está diseñado para reflejar el rendimiento de los 200 componentes del S&P 500 con el sentimiento más positivo en Twitter.
Fear and Greed Index	Recopila datos de cinco fuentes. Cada punto de datos se valora igual que el día anterior para visualizar un progreso significativo en el cambio de sentimiento del mercado criptográfico.

Tabla 6.1: Indicadores de bolsas Latinoamericanas, índices del miedo e indicadores de pandemia

En la tabla 6.3, muestra el detalle de las empresas listadas en los índices, utilizadas en el estudio para la construcción de factores de tamaño (SMB), ratio book to market (HML) y de momentum (WML).

Empresa	Índice	Sector Industrial
SQM-B	IPSA	Materias Primas
CHILE	IPSA	Banca
BSANTANDER	IPSA	Banca
COPEC	IPSA	Materias Primas
CENCOSUD	IPSA	Retail

FALABELLA	IPSA	Retail
ENELAM	IPSA	Servicios Básicos
BCI	IPSA	Banca
CMPC	IPSA	Materias Primas
VAPORES	IPSA	Marítimas y Navieras
CAP	IPSA	Minería
CCU	IPSA	Consumo
QUINENCO	IPSA	Holding
ANDINA-B	IPSA	Consumo
CONCHATORO	IPSA	Consumo
ENELCHILE	IPSA	Servicios Básicos
PARAUCO	IPSA	Construcción / Inmobiliaria
ITAUCORP	IPSA	Banca
ENTEL	IPSA	TI / Telecomunicaciones
AGUAS-A	IPSA	Servicios Básicos
COLBUN	IPSA	Servicios Básicos
CENCOSHOPP	IPSA	Construcción / Inmobiliaria
MALLPLAZA	IPSA	Construcción / Inmobiliaria
IAM	IPSA	Holding
SMU	IPSA	Retail
ECL	IPSA	Servicios Básicos
SONDA	IPSA	TI
RIPLEY	IPSA	Retail
SECURITY	IPSA	Holding
Grupo Financiero Inbursa	BMV IPC	Servicios financieros
Corp Inmobiliaria Vesta	BMV IPC	Construcción / Inmobiliaria
Gruma	BMV IPC	Consumo
Wal-Mart de México	BMV IPC	Consumo
Bolsa Mexicana de Valores	BMV IPC	Bolsa de Valores
Industrias Peñoles	BMV IPC	Materiales
Grupo Financiero Banorte	BMV IPC	Servicios Financieros
Arca Continental	BMV IPC	Consumo

Promotora y Operadora de Infra	BMV IPC	TI
Operadora de Sites mexicanos	BMV IPC	Telecomunicaciones
Alsa	BMV IPC	Consumo
Grupo Aeroportuario del Centro	BMV IPC	Industrial
Becle	BMV IPC	Consumo
América Móvil	BMV IPC	Telecomunicaciones
Alfa	BMV IPC	Industrial
Grupo Bimbo	BMV IPC	Consumo
El Puerto de Liverpool	BMV IPC	Consumo
Grupo Aeroportuario del Sureste	BMV IPC	Industrial
Grupo México	BMV IPC	Materiales
Banco del Bajío	BMV IPC	Servicios Financieros
Genomma Lab Internacional	BMV IPC	Salud
Cemex	BMV IPC	Materiales
Orbia Advance Corp	BMV IPC	Materiales
Grupo Carso	BMV IPC	Industrial
GCC	BMV IPC	Materiales
Regional	BMV IPC	Servicios Financieros
Kimberly-Clark de México	BMV IPC	Consumo
Grupo Elektra	BMV IPC	Consumo
Qualitas Controladora	BMV IPC	Servicios Financieros
Grupo Aeroportuario del Pacífico	BMV IPC	Industrial
Coca-Cola Femsá	BMV IPC	Consumo
Megacable Holdings	BMV IPC	Holding
Grupo Televisa	BMV IPC	Telecomunicaciones
Controladora Vuela Cía. de Aviación	BMV IPC	Industrial
Fomento Económico Mexicano	BMV IPC	Consumo
Almacenes Éxito	COLCAP	Retail
Banco de Bogotá	COLCAP	Banca
Bancolombia	COLCAP	Banca
Canacol Energy	COLCAP	Petróleo
Celsia	COLCAP	Energía

Cementos Argos	COLCAP	Materiales de construcción
Cemex Latam	COLCAP	Materiales de construcción
Bolsa de Valores de Colombia	COLCAP	Bolsa de valores
Corficolombiana	COLCAP	Servicios financieros
Davivienda	COLCAP	Banca
Ecopetrol	COLCAP	Petróleo
Empresa de Energía de Bogotá	COLCAP	Energía
Grupo Argos	COLCAP	Conglomerado
Grupo Aval	COLCAP	Banca
Grupo Nutresa	COLCAP	Industria alimenticia
Grupo Sura	COLCAP	Conglomerado
Interconexión Eléctrica	COLCAP	Energía
Pacific Exploration & Production	COLCAP	Petróleo
AENZA	SP PERU SELECT	Industrial
ALICORP	SP PERU SELECT	Consumo
BBVA	SP PERU SELECT	Financiera
PACASMAYO	SP PERU SELECT	Materiales
BUENAVENTURA	SP PERU SELECT	Materiales
CREDICORP	SP PERU SELECT	Financiera
FERREYCORP	SP PERU SELECT	Industrial
INRETAIL	SP PERU SELECT	Consumo
INTERCORP	SP PERU SELECT	Financiera
MINSUR	SP PERU SELECT	Diversas
CERRO VERDE	SP PERU SELECT	Mineras
SOUTHERN COPPER	SP PERU SELECT	Materiales
TREVALI	SP PERU SELECT	Materiales
UNACEM	SP PERU SELECT	Industrial
VOLCAN	SP PERU SELECT	Materiales

Tabla 6.2: Empresas consideradas en el estudio por índice del MILA

Figura 6.3: Evolución de precios diarios del índice IPSA, Fuente: Elaboración Propia. Software utilizado Rstudio.




Figura 6.4: Evolución de precios diarios del índice BMV IPC, Fuente: Elaboración Propia. . Software utilizado Rstudio.




Figura 6.5: Evolución de precios diarios del índice COLCAP, Fuente: Elaboración Propia. .
Software utilizado Rstudio.





Figura 6.6: Evolución de precios diarios del índice SP_PERU_SELECT, Fuente: Elaboración Propia. . Software utilizado Rstudio.



En las figuras 6.3 a la 6.6: El intervalo indicado como período de pandemia está delimitado como fin, corresponde cuando los países empiezan a flexibilizar las cuarentenas y permiten la movilidad de las personas de acuerdo con la vacunación contra el virus. En la evolución de los precios de los índices comprendidos se visualiza claramente la caída de los precios a partir del primer caso en los países de COVID-19, posterior a las fechas de mayor flexibilidad de

movilidad de las personas, en tres países se comienza a recuperar el precio del índice, salvo Perú que tiene una caída en periodo posterior, pero se recupera rápidamente. En Chile, si bien el precio es superior al comienzo de la pandemia, es más volátil la recuperación con respecto a México y Colombia.

El modelo propuesto para los mercados es el siguiente:

Al modelo original de Fama Cahart de cuatro factores se agregan cinco factores, que son datos que se utilizan para capturar el temor o miedo en medio de la incertidumbre, agregando comportamiento de los agentes de los mercados y crecimiento de los nuevos casos COVID-19:

$$r_{i,t} = \alpha + \beta_1 * RMRF_t + \beta_2 * SMB_t + \beta_3 * HML_t + \beta_4 * WML_t + \gamma_1 * NC_t + \gamma_2 * VIX_t + \gamma_3 * SPT_t + \gamma_4 * FG_t + \gamma_5 * V2X_t + \varepsilon_t$$

Donde:

$r_{i,t}$: Retorno del índice i en tiempo t, $r_{m,t}$: Premio por riesgo ($R_m - R_f$) en tiempo t, SMB_t : Factor de tamaño (Small Minus Big) en tiempo t, HML_t : Factor de valor (High Minus Low) en tiempo t, WML_t : Factor Momentum (Winner Minus Loser) en período t, NC_t : Factor de nuevos casos de COVID-19 en tiempo t, VIX_t : Factor de volatilidad en tiempo t, SPT_t : SP500 Sentiment Twitter en periodo t, SPT_t : Factor de SP500 Sentiment Twitter en tiempo t, FG_t : Fear and Greed index en tiempo t, $V2X_t$: Volatilidad en Eurozona en tiempo t.

6.5.-Metodología

Los datos de panel se refieren a datos multidimensionales recopilados durante un tiempo determinado. Una regresión de datos de panel simple se puede especificar de la siguiente forma:

$$Y_{it} = a + bX_{it} + \varepsilon_{it}$$

Donde Y_{it} , corresponde a la variable dependiente en período t, X_{it} : es la variable independiente o explicativa en periodo t, a y b: son los coeficientes y ε_{it} : termino de error en periodo t.

La prueba propuesta por (Hausman, 1978), es un test chi cuadrado el cual examina si las diferencias son sistemáticas y significativas entre dos estimaciones. Se ocupa principalmente para saber si un estimador es consistente y puede ser relevante o no, para ser incorporada en un modelo de estimación.

El análisis de regresión de datos de panel se puede realizar principalmente de tres formas:

1) Modelo de regresión agrupada en forma independiente.

Este tipo de modelo de datos de panel asume la homogeneidad de todas las secciones de datos en un estudio de datos de panel que es no trata cada sección de manera diferente.

2) Modelo de efectos fijos.

Este tipo de modelo permite heterogeneidad o individualidad entre diferentes secciones transversales, lo que permite cada sección transversal tenga su propio intercepto. En resumen, la intersección puede ser diferente para las secciones transversales, pero es invariable en el tiempo, es decir, la intersección permanece igual a lo largo del tiempo. Se supone que el término de error en un modelo de efectos fijos varía de forma no estocástica en cada entidad y tiempo. Existen únicos atributos de los individuos que no varían a lo largo del tiempo y está correlacionado con variables independientes.

3) Modelo de efectos aleatorios.

El modelo de efectos aleatorios también permite heterogeneidad y también es invariable en el tiempo, pero el efecto específico individual no está correlacionado con las variables independientes.

Esta prueba nos permite establecer qué modelo es más consistente y eficiente. Para este proceso se establece la hipótesis de que no existe correlación entre las variables explicativas y los efectos individuales. La hipótesis nula establece que el estimador del modelo de efectos aleatorios es consistente y eficiente mientras que el de efectos fijos es sólo consistente. En consecuencia, al aceptar la hipótesis nula se acepta el modelo de efectos aleatorios.

La pregunta que necesitamos responder con esta metodología es ¿cómo se estiman estos modelos y como se hace la elección correcta del modelo?

Un modelo de efectos fijos es mejor si tenemos datos de todos los miembros de la población, en cambio cuando tenemos una población más grandes y tenemos una muestra aplicar el modelo de efectos aleatorios es mejor y nos ahorra grados de libertad debido a que algunos de los parámetros son variables aleatorias. Ahora bien, un modelo de efectos aleatorios tiene la desventaja de suponer que el error asociado con cada unidad de corte transversal no está correlacionado con

los otros regresores; pero es poco probable que esto suceda. Si este supuesto no se cumple, el estimador de modelo aleatorio estaría sesgado.

Para decidir entre efectos fijos o aleatorios, se realizará por medio de test de Hausman, test donde la hipótesis nula es que el modelo que se utilizará es el de efectos aleatorios frente a la alternativa de efectos fijos. (Greene 2002).

El estadístico F es una prueba que se utiliza para evaluar la capacidad explicativa que tiene un grupo de variables independientes sobre la variación de la variable dependiente del modelo sometido a evaluación.

$$F = \frac{\frac{SCR}{k}}{\frac{SCE}{n-k-1}}$$

Donde: SCR: Suma de cuadrados de la regresión, SCE: Suma de cuadrados de los residuos, N: Número total de las observaciones de la muestra, K: Grados de libertad.

6.5.1.-Prueba al modelo multifactorial de comportamiento

Para probar la hipótesis en las acciones que componen los índices de los países en estudio, en primer lugar, se estiman modelos de regresión de datos de panel, calculando los modelos de regresión combinados, de efectos fijos y de efectos aleatorios.

Definición de ecuaciones a examinar:

- Ecuación 1: Cahart Fama French (CF4F)
- Ecuación 2: Factores de Comportamiento y Volatilidad
- Ecuación 3: Cahart Fama French de cuatro factores más extensión de factores de comportamiento y volatilidad.
- Ecuación 4: Factores de volatilidad.
- Ecuación 5: Factores de Comportamiento.

ID	ECUACIONES PARA ESTIMAR
1	$r_{i,t} = \alpha + \beta_1 * r_{m,t} + \beta_2 * SMB_t + \beta_3 * HML_t + \beta_4 * WML_t$
2	$r_{i,t} = \alpha + \gamma_1 * NC_t + \gamma_2 * VIX_t + \gamma_3 * SPT_t + \gamma_4 * FG_t + \gamma_5 * V2X_t + \varepsilon_t$

3	$r_{i,t} = \alpha + \beta_1 * r_{m,t} + \beta_2 * SMB_t + \beta_3 * HML_t + \beta_4 * WML_t + \gamma_1 * NC_t + \gamma_2 * VIX_t + \gamma_3 * SPT_t + \gamma_4 * FG_t + \gamma_5 * V2X_t + \varepsilon_t$
4	$r_{i,t} = \alpha + \beta_1 * r_{m,t} + \gamma_2 * VIX_t + \gamma_5 * V2X_t + \varepsilon_t$
5	$r_{i,t} = \alpha + \beta_1 * r_{m,t} + \gamma_1 * NC_t + \gamma_3 * SPT_t + \gamma_4 * FG_t + \varepsilon_t$

Tabla 6.3: Ecuaciones consideradas en el estudio

6.6.-Resultados

Factor	N	Media	Desv. Std.	Skewness	Curtosis	Min.	Max.
RM-RF	588	-0,0009	0,0313	-2.5130	30.15	-0.3394	0.1482
SMB	588	-0.0010	0.0101	0.6132	15.70	-0.0610	0.0822
HML	588	0.0009	0.0088	0.2029	7.61	-0.0382	0.0468
WML	588	0.0014	0.0111	-0.3109	15.06	-0.0840	0.0678
VIX	588	0.0009	0.0866	1.2921	7.76	-0.2662	0.4802
V2X	588	0.0010	0.0864	1.0507	5.80	-0.2041	0.0909
SP500_Twitter	588	0.0006	0.0154	-0.8875	17.72	-0.1238	0.0909
NC	588	0.0728	0.2422	4.5621	93.00	-1.6360	3.6394
FG	588	0.0011	0.1867	0.0308	8.04	-0.8329	0.9360

Tabla 6.4: Estadísticos del Índice IPSA. Software utilizado Eviews.

En la tabla 6.5, presentan el análisis estadístico descriptivo de la rentabilidad de índice de mercado, donde se aprecia que el rendimiento del índice en el período obtiene un promedio negativo (-0,09% diario) concordante con las dos crisis que componen el período de estudio, revisando la asimetría (Skewness), que mide la asimetría de las distribuciones de probabilidad, muestra que el índice se encuentra sesgado negativamente, este provocaría una mayor probabilidad de disminución de los rendimientos. Con respecto al factor de riesgo, SMB obtiene un retorno promedio negativo, y con asimetría sesgado positivamente obteniendo mayor probabilidad de aumento del coeficiente. Los demás factores de riesgo (HML, WML, VIX, V2X, NC y FG), obtienen promedios positivos, con probabilidad de aumento positivo del coeficiente. Por último, el factor SP500 Twitter Sentiment obtienen coeficiente promedio positivo, pero con mayor probabilidad a disminuir.

Factor	N	Media	Desv. Std.	Skewness	Curtosis	Min.	Max.
RM-RF	588	0.0010	0.0202	-1.0457	10.48	0.0016	0.0748
SMB	588	-0.0002	0.0076	-0.7893	9.82	0.0002	0.0316

HML	588	0.0001	0.0078	0.0408	4.75	0.0002	0.0366
WML	588	0.0007	0.0077	-0.7748	8.85	0.0006	0.0295
VIX	588	0.0005	0.0856	1.2245	7.64	-0.0075	0.4802
V2X	588	0.0014	0.0864	1.0382	5.80	-0.0090	0.4856
SP500_Twitter	588	0.0008	0.0145	-0.0166	13.18	0.0010	0.0909
NC	588	0.0717	0.2411	4.6674	95.19	0.0398	3.6394
FG	588	0.0030	0.1881	0.0510	7.94	0.0000	0.9360

Tabla 6.5: Estadísticos del Índice BMV IPC. Software utilizado Eviews.

En la tabla 6.6, presentan el análisis estadístico descriptivo de la rentabilidad del índice de mercado, donde se aprecia que el rendimiento del índice en el período obtiene un promedio negativo (0,1% diario) concordante con las dos crisis que componen el período de estudio, revisando la asimetría (Skewness), que mide la asimetría de las distribuciones de probabilidad, muestra que el índice se encuentra sesgado negativamente, esto provocaría una mayor probabilidad de disminución de los rendimientos. Con respecto al factor de riesgo, SMB obtiene un retorno promedio negativo, y con asimetría sesgada negativamente obteniendo mayor probabilidad de disminución del coeficiente. Los demás factores de riesgo (HML, WML, VIX, V2X, NC y FG), obtienen promedios positivos, con probabilidad de aumento positivo del coeficiente. Por último, el factor SP500 Twitter Sentiment obtienen coeficiente promedio positivo, pero con mayor probabilidad a disminuir.

Factor	N	Media	Desv. Std.	Skewness	Curtosis	Min.	Max.
RM-RF	568	-0.0007	0.0308	-1.4127	30.73	-0.2410	0.2308
SMB	568	-0.0003	0.0105	-0.4743	7.09	-0.0629	0.0479
HML	568	0.0005	0.0111	0.3037	14.36	-0.0807	0.0827
WML	568	0.0006	0.0106	0.7122	13.12	-0.0672	0.0798
VIX	568	0.0022	0.0868	1.3400	7.69	-0.2203	0.4802
V2X	568	0.0009	0.0873	1.0530	5.76	-0.2041	0.4856
SP500_Twitter	568	0.0003	0.0151	-1.2771	17.33	-0.1238	0.0825
NC	568	0.0699	0.2432	4.6615	94.85	-1.6360	3.6394
FG	568	0.0030	0.1898	0.0479	7.87	-0.8329	0.9360

Tabla 6.6: Estadísticos del Índice COLCAP. Software utilizado Eviews.

En la tabla 6.7, presentan el análisis estadístico descriptivo de la rentabilidad de índice de mercado, donde se aprecia que el rendimiento del índice en el período obtiene un promedio negativo (-0,07% diario) concordante con las dos crisis que componen el período de estudio, revisando la asimetría (Skewness), que mide la asimetría de las distribuciones de probabilidad, muestra que el índice se encuentra sesgado negativamente, esto provocaría una mayor probabilidad de disminución de los rendimientos. Con respecto al factor de riesgo, SMB obtiene un retorno promedio negativo, y con asimetría sesgada negativamente obteniendo mayor probabilidad de disminución del coeficiente. Los demás factores de riesgo (HML, WML, VIX, V2X, NC y FG), obtienen promedios positivos, con probabilidad de aumento positivo del coeficiente. Por último, el factor SP500 Twitter Sentiment obtienen coeficiente promedio positivo, pero con mayor probabilidad a disminuir.

Factor	N	Media	Desv. Std.	Skewness	Curtosis	Min.	Max.
RM-RF	595	-0.0011	0.0313	-1.9215	22.7140	-0.2759	0.1871
SMB	595	0.0004	0.0195	6.2121	99.6826	-0.0610	0.3041
HML	595	-0.0003	0.0184	-10.757	199.3564	-0.3423	0.0380
WML	595	0.0018	0.0199	7.5247	125.5150	-0.0609	0.3296
VIX	595	0.0013	0.0867	1.2650	7.6376	-0.2662	0.4802
V2X	595	0.0015	0.0862	1.0369	5.7760	-0.2041	0.4856
SP500_Twitter	595	0.0006	0.0153	-0.8713	17.6664	-0.1238	0.0909
NC	595	0.0721	0.2431	4.4650	90.8201	-1.6360	3.6394
FG	595	-0.0003	0.1875	0.0331	7.9523	-0.8329	0.9360

Tabla 6.7: Estadísticos del Índice SP_PERU_SELECT. Software utilizado Eviews.

En la tabla 6.8, presentan el análisis estadístico descriptivo de la rentabilidad de índice de mercado, donde se aprecia que el rendimiento del índice en el período obtiene un promedio negativo (-0,11% diario) concordante con las dos crisis que componen el período de estudio, revisando la asimetría (Skewness), que mide la asimetría de las distribuciones de probabilidad, muestra que el índice se encuentra sesgado negativamente, esto provocaría una mayor probabilidad de disminución de los rendimientos. Con respecto al factor de riesgo, SMB obtiene un retorno promedio positivo, y con asimetría sesgada positivamente, que indicaría que el coeficiente aumenta en el tiempo. Los demás factores de riesgo (WML, VIX, V2X, SP500_Twitter, NC), obtienen promedios positivos, con probabilidad de aumento positivo del coeficiente en los factores de VIX, V2X y

NC y de crecimiento negativo en los factores de WML, SP500 Twitter. Por último, el factor FG obtienen coeficiente promedio negativo, pero con mayor probabilidad de aumento negativo.

	Ecuación (1)	Ecuación (2)	Ecuación (3)	Ecuación (4)	Ecuación (5)
F-Test	356.0101	98.25620	414.6355	458.0462	435.0546
P-Value	0.0000	0.0000	0.0000	0.0000	0.0000
Hausman Test	0.0000	0.0000	0.0000	0.0000	0.0000
P-Value	1.0000	1.0000	1.0000	1.0000	1.0000

Tabla 6.8: IPSA. Software utilizado Stata.

En la Tabla 6.9 presentamos los resultados de las pruebas F y Hausman de cada una de las 5 regresiones de panel. Los resultados de todos los modelos de regresión muestran que el modelo de efectos aleatorios es el más apropiado para nuestros datos de panel balanceados. Además, la prueba F el p-value es inferior al 5%, lo que sugiere que la regresión combinada y los efectos aleatorios conducen a resultados de ajuste similares, es decir, las variables en su conjunto aportan a la explicación de la variable dependiente.

	Ecuación (1)	Ecuación (2)	Ecuación (3)	Ecuación (4)	Ecuación (5)
Intercepto	0.0003	-0.0001	0.0004	0.0005	0.0004
P-Value	(0.1549)	(0.6905)	(0.0170) **	(0.0305) *	(0.0502) ***
RM-RF	0.4040		0.3607	0.3849	0.3715
P-Value	(0.0000) *		(0.0000) *	(0.0000) *	(0.0000) *
SMB	-0.0926		-0.0323		
P-Value	(0.0055) *		(0.1434)		
HML	0.0850		0.1099		
P-Value	(0.0236) *		(0.0000) *		
WML	-0.0064		-0.0279		
P-Value	(0.7767)		(0.0623) ***		
VIX		0.0202	-0.0040	-0.0288	
P-Value		(0.0000) *	(0.1691)	(0.0000) *	
V2X		-0.0469	-0.0264	-0.0284	
P-Value		(0.0000) *	(0.0000) *	(0.0000) *	
SP500_TWITTER		0.4841	0.2112		0.2937
P-Value		(0.0000) *	(0.0000) *		(0.0000) *
NC		-0.0003	-0.0019		-0.0025
P-Value		(0.7295)	(0.0043) *		(0.0076) *
FG		-0.0006	0.0017		0.0015
P-Value		(0.6809)	(0.0475) **		(0.2231)
R²	0.49	0.21	0.56	0.53	0.54

LLF (1)	8543.021	9488.644	17504.64	6948.177	8695.664
AIC (2)	-5.80	-5.37	-5.94	-5.90	-5.90

Tabla 6.9: Resultado de regresiones de panel aleatoria, para la variable dependiente del índice IPSA. . Software utilizado Stata.

(1) LLF: Representa el valor de la función de verosimilitud en los parámetros, útil para la interpretación del ratio de verosimilitud

(2) AIC: el criterio es elegir el modelo que logre el menor valor

En la tabla 6.10, se muestran los resultados del índice IPSA, donde los factores que logran significancia estadística, es decir son variables explicativas del índice se marcan con asterisco (* 1%, ** 5% y *** 10%), también se observa en la función LLF (Log verosimilitud) y el criterio de información (AIC), el modelo que mejor se ajusta es el modelo Fama Cahart de cuatro factores con extensión de noticias de redes sociales, factor de miedo de las criptomonedas, de nuevos casos de COVID-19 a nivel mundial y de volatilidad, Además, la R^2 sugiere que este modelo tiene el nivel de explicación más alto es la ecuación 3, además en la mayoría de los factores de riesgo utilizados logran significancia estadística al menos al 10%, lo que indica que estos factores en alguna medida explican los rendimientos del índice de este mercado en el periodo de crisis. Analizando el efecto de los factores de riesgo: El coeficiente de mercado es positivo en el periodo, donde el estimador de factor tamaño es negativo, esperable en tiempo de crisis, como los coeficientes del factor momentum (WML) y los coeficientes que miden volatilidad (VIX, V2X) y el factor construido a partir de nuevos casos de COVID-19, finalmente los estimadores de sentimiento del mercado (SP500 Twitter y FG) son positivos. Los estimadores más relevantes son el de factor de mercado, el estimador del índice de SP500 Twitter Sentiment, el de ratio valor (HML), de momentum (WML) y de volatilidad de eurozona (V2X).

	Ecuación (1)	Ecuación (2)	Ecuación (3)	Ecuación (4)	Ecuación (5)
F-Test	635.79	180.59	683.65	485.74	487.36
P-Value	0.0000	0.0000	0.0000	0.0000	0.0000
Hausman Test	0.0000	0.0000	0.0000	0.0000	0.0000
P-Value	1.0000	1.0000	1.0000	1.0000	1.0000

Tabla 6.10: BMV IPC. Software utilizado Stata.

En la Tabla 6.11, muestra los resultados de las pruebas F y Hausman de cada una de las 5 regresiones de panel. Los resultados de todos los modelos de regresión muestran que el modelo de efectos aleatorios es el más apropiado para nuestros datos de panel balanceados. Esto es así porque el valor p-value de la prueba F es

inferior al 5 %, lo que sugiere que la regresión combinada y los efectos aleatorios conducen a resultados de ajuste similares.

	Ecuación (1)	Ecuación (2)	Ecuación (3)	Ecuación (4)	Ecuación (5)
Intercepto	-0.0002	0.0003	-0.0002	0.0001	0.0000
P-Value	(0.1360)	(0.0728)***	(0.0327)*	(0.4487)	(0.8446)
RM-RF	0.4010		0.3314	0.3882	0.3661
P-Value	(0.0000)*		(0.0000)*	(0.0000)*	(0.0000)*
SMB	-0.1925		-0.1704		
P-Value	(0.0000)*		(0.0000)*		
HML	-0.3235		-0.2716		
P-Value	(0.0000)*		(0.0000)*		
WML	0.3902		0.3738		
P-Value	(0.0000)*		(0.0000)*		
VIX		0.0060	0.0050	-0.0143	
P-Value		(0.0480)*	(0.0023)*	(0.0000)*	
V2X		-0.0344	-0.0174	-0.0201	
P-Value		(0.0000)*	(0.0000)*	(0.0000)*	
SP500_TWITTER		0.3983	0.1622		0.2234
P-Value		(0.0000)*	(0.0000)*		(0.0000)*
NC		-0.0015	-0.0003		-0.0013
P-Value		(0.0251) *	(0.3460)		(0.0331)*
FG		0.0003	-0.0012		-0.0009
P-Value		(0.6705)	(0.0109)*		(0.2510)
R²	0.63	0.34	0.67	0.55	0.57
LLF	10168.66	11160.13	20704.04	7901.936	9933.504
AIC	-6.93	-6.34	-7.05	-6.73	-6.77

Tabla 6.11: BMV IPC. Software utilizado Stata.

(1) LLF: Representa el valor de la función de verosimilitud en los parámetros, útil para la interpretación del ratio de verosimilitud

(2) AIC: el criterio es elegir el modelo que logre el menor valor

En la tabla 6.12, se muestran los resultados del índice BMV IPC, donde los factores que logran significancia estadística, es decir son variables explicativas del índice se marcan con asterisco (* 1%, ** 5% y *** 10%), también se observa en la función LLF (Log verosimilitud) y el criterio de información (AIC), el modelo que mejor se ajusta es el modelo Fama Cahart de cuatro factores con extensión de noticias de redes sociales, factor de miedo de las criptomonedas, de nuevos casos de COVID-19 a nivel mundial y de volatilidad (Ecuación 3), el estimador de mercado es positivo, al igual que los estimadores de volatilidad (VIX), momemtum (WML) y de sentimiento del inversor SP500_Twitter, los

estimadores negativos lo obtienen los estimadores de tamaño (SMB), valor (HML), volatilidad de la eurozona (V2X), nuevos casos mundiales de COVID-19 (NC) y el estimador del miedo y codicia de las criptomonedas (FG). Los estimadores más relevantes son el de factor de mercado, de momentum (WML), de valor (HML), de tamaño (SMB), SP500 Twitter Sentiment y de volatilidad de eurozona (V2X).

	Ecuación (1)	Ecuación (2)	Ecuación (3)	Ecuación (4)	Ecuación (5)
F-Test	1269.226	137.6502	1148.572	1092.061	1019.953
P-Value	0.0000	0.0000	0.0000	0.0000	0.0000
Hausman Test	0.0000	0.0000	0.0000	0.0000	0.0000
P-Value	1.0000	1.0000	1.0000	1.0000	1.0000

Tabla 6.12: COLCAP. Software utilizado Stata.

En la Tabla 6.13, se muestran los resultados de las pruebas F y Hausman de cada una de las 5 regresiones de panel. Los resultados de todos los modelos de regresión muestran que el modelo de efectos aleatorios es el más apropiado para nuestros datos de panel balanceados. Esto es así porque el valor p-value de la prueba F es inferior al 5 %, lo que sugiere que la regresión combinada y los efectos aleatorios conducen a resultados de ajuste similares.

	Ecuación (1)	Ecuación (2)	Ecuación (3)	Ecuación (4)	Ecuación (5)
Intercepto	0.0002	-0.0003	0.0001	0.0004	0.0003
P-Value	(0.0832)***	(0.2270)	(0.0793)***	(0.0188)*	(0.0435)*
RM-RF	0.3905		0.3753	0.4640	0.4612
P-Value	(0.0000)*		(0.0000)*	(0.0000)*	(0.0000)*
SMB	-0.3832		-0.3927		
P-Value	(0.0000)*		(0.0000)*		
HML	-0.3090		-0.3227		
P-Value	(0.0000)*		(0.0000)*		
WML	0.2202		0.2157		
P-Value	(0.0000)*		(0.0000)*		
VIX		0.0294	-0.0047	-0.0011	
P-Value		(0.0000)*	(0.0130)*	(0.6482)	
V2X		-0.0244	-0.0078	-0.0072	
P-Value		(0.0000)*	(0.0000)*	(0.0044)*	
SP500_TWITTER		0.6316	0.0003		0.0359
P-Value		(0.0000)*	(0.9730)		(0.0061)*
NC		0.0011	0.0011		0.0008
P-Value		(0.2406)	(0.0099)*		(0.2183)
FG		0.0039	0.0009		0.0004

P-Value		(0.0022)*	(0.0949)***		(0.5816)
R²	0.78	0.28	0.78	0.74	0.74
LLF	9722.913	9651.727	19486.04	7592.024	9486.145
AIC	-6.84	-5.65	-6.85	-6.67	-6.67

Tabla 6.13: COLCAP. Software utilizado Stata.

(1) LLF: Representa el valor de la función de verosimilitud en los parámetros, útil para la interpretación del ratio de verosimilitud

(2) AIC: el criterio es elegir el modelo que logre el menor valor

En la tabla 6.14, se muestran los resultados del índice COLCAP, donde los factores que logran significancia estadística, es decir son variables explicativas del índice se marcan con asterisco (* 1%, ** 5% y *** 10%), también se observa en la función LLF (Log verosimilitud) y el criterio de información (AIC), el modelo que mejor se ajusta es el modelo Fama Cahart de cuatro factores con extensión de noticias de redes sociales, factor de miedo de las criptomonedas, de nuevos casos de COVID-19 a nivel mundial y de volatilidad (Ecuación 3), el estimador de mercado es positivo, que el estimador de momemtum (WML), de sentimiento del inversor SP500_Twitter, nuevos casos mundiales de COVID-19 (NC) y el estimador del miedo y codicia de las criptomonedas (FG). los estimadores negativos lo obtienen los estimadores de tamaño (SMB), valor (HML), volatilidad de la eurozona (V2X) y de volatilidad (VIX). Ahora bien, si bien los estimadores de comportamiento y volatilidad son bastante bajos, con respecto a los factores de riesgo del modelo de CF4F en la ecuación 3 que obtiene mejor coeficiente de determinación, sin embargo, en este mercado los estimadores de comportamiento y de sentimiento del inversor aportan muy poco, en el fondo son insignificantes.

	Ecuación (1)	Ecuación (2)	Ecuación (3)	Ecuación (4)	Ecuación (5)
F-Test	384.39	140.34	421.81	467.88	442.35
P-Value	0.0000	0.0000	0.0000	0.0000	0.0000
Hausman Test	0.0000	0.0000	0.0000	0.0000	0.0000
P-Value	1.0000	1.0000	1.0000	1.0000	1.0000

Tabla 6.14: SPPERU_SELECT. Software utilizado Stata.

En la Tabla 6.15, se muestran los resultados de de cada una de las 5 regresiones de panel. Los resultados de todos los modelos de regresión muestran que el modelo de efectos aleatorios es el más apropiado para nuestros datos de panel balanceados. Esto es así porque el valor p-value de la prueba F es inferior al 5 %, lo que sugiere que la regresión combinada y los efectos aleatorios conducen a resultados de ajuste similares.

	Ecuación (1)	Ecuación (2)	Ecuación (3)	Ecuación (4)	Ecuación (5)
Intercepto	0.0005	0.0001	0.0004	0.0007	0.0005
P-Value	(0.0074)**	(0.5104)	(0.0018)*	(0.0008)*	(0.0106)*
RM-RF	0.3469		0.2921	0.3153	0.2957
P-Value	(0.0000)*		(0.0000)*	(0.0000)*	(0.0000)*
SMB	0.0256		-0.0060		
P-Value	(0.0324)*		(0.4546)		
HML	0.0806		0.0472		
P-Value	(0.0000)*		(0.0000)*		
WML	0.0907		0.0715		
P-Value	(0.0000)*		(0.0000)*		
VIX		0.0079	-0.0013	-0.0221	
P-Value		(0.0461)*	(0.5807)	(0.0000)*	
V2X		-0.0320	-0.0209	-0.0219	
P-Value		(0.0000)*	(0.0000)*	(0.0000)*	
SP500_TWITTER		0.4654	0.1796		0.2397
P-Value		(0.0000)*	(0.0000)*		(0.0000)*
NC		-0.0006	0.0000		-0.0003
P-Value		(0.4795)	(0.8702)		(0.6510)
FG		0.0008	-0.0001		-0.0009
P-Value		(0.4811)	(0.8697)		(0.3792)
R²	0.51	0.28	0.56	0.54	0.54
LLF	9100.799	10248.66	18534.65	7362.477	9209.916
AIC	-6.20	-5.82	-6.31	-6.27	-6.28

Tabla 6.15: SP PERU SELECT. Software utilizado Stata.

(1) LLF: Representa el valor de la función de verosimilitud en los parámetros, útil para la interpretación del ratio de verosimilitud

(2) AIC: el criterio es elegir el modelo que logre el menor valor

En la tabla 6.16, se muestran los resultados del índice SP Perú Select, donde los factores que logran significancia estadística, es decir son variables explicativas del índice se marcan con asterisco (* 1%, ** 5% y *** 10%), también se observa en la función LLF (Log verosimilitud) y el criterio de información (AIC), el modelo que mejor se ajusta es el modelo Fama Cahart de cuatro factores con extensión de noticias de redes sociales, factor de miedo de las criptomonedas, de nuevos casos de COVID-19 a nivel mundial y de volatilidad (Ecuación 3), el estimador de mercado es positivo, al igual que estimador del ratio valor (HML), estimador de momemtum (WML), de sentimiento del inversor SP500_Twitter, nuevos casos mundiales de COVID-19 (NC). los coeficientes negativos lo obtienen los estimadores del factor tamaño (SMB), volatilidad de la eurozona (V2X), de volatilidad (VIX) y el estimador del miedo y codicia de las criptomonedas (FG).

En este caso, la ecuación 3, el estimador de sentimiento SP500 Twitter Sentiment es relevante para el índice al igual que el índice, de volatilidad V2X que no es tan insignificante.

6.7.-Conclusión del capítulo

La importancia de los nuevos factores de riesgo, de volatilidad, sentimiento de los inversores, además de factores que vienen desde datos de la pandemia del COVID-19, es la superación del supuesto de aversión al riesgo de los agentes, que se considera como una constante en los modelos de valoración clásicos. Los cambios en la volatilidad de acuerdo a eventos en mercados emergentes ya sean cambios políticos, fallas en los mercados, problemas ecológicos y en este caso la crisis sanitaria ha sido establecida y verificada por estudios anteriores. (Aggarwal, Inclan, & Leal, 1999).

La inclusión del sentimiento de los inversionistas a los modelos de valoración es un aporte que va en el sentido de buscar mayor rendimiento de los modelos de valoración de activos, además se hace cargo de la discusión que se ha estado analizando últimamente, que es la inclusión del sentimiento del inversor en su forma más funcional a los modelos de valoración. Existen estudios a partir de la crisis sanitaria que corroboran la importancia de obtener los sentimientos desde redes sociales actualmente por medio de los comentarios o Tweet (Red social Twitter) o a través de un motor de búsquedas como Google o Baidu según la zona geográfica del estudio. Esta información procesada a partir de herramientas actuales de la inteligencia artificial y de la estadística y econometría, pueden ayudar a explicar los rendimientos de los activos en períodos de crisis. (Chahuán-Jiménez & Riffo Rosas, 2022). (Jiang, Zhu, Zhang, Yan, & Shen, 2021) (Mendoza-Urdiales, Núñez-Mora, & Santillán-Salgado, 2022)

Existen escasos estudios acerca de extender un modelo de valoración de activos, utilizando datos de los índices que componen el mercado integrado latinoamericano (MILA). En esta investigación se extiende el modelo de Fama Cahart de cuatro factores, con variables de volatilidad y de sentimiento específicamente que capturan el miedo de los mercados, como lo es el índice SP500 Twitter Sentiment. Existe muchos factores que se han probado en el tiempo en el modelo de valoración, como variables macroeconómicas, climáticas, commodities, etc. Cabe señalar que esta tesis no busca probar variables de este tipo, sino aquellas que puedan entregar información acerca del comportamiento de los agentes del mercado, buscando superar el supuesto de aversión al riesgo,

o de cierta racionalidad de los participantes del mercado de valores en países sudamericanos. Partiendo de la base de la eficiencia financiera débil ([Ruiz Dávila & García Muñoz, 2020](#)), comprueba la eficiencia débil anterior a la pandemia en los mercados de Chile, Colombia y México, sin embargo, en el mercado peruano es posible lograr ganancias extraordinarias, ya que no se encuentra en eficiencia débil establecida por Fama y French.

Existe un estudio que busca explicar la caída del mercado brasileño, rescatando mensajes de Twitter (Twitter Investor Sentiment Index (ISI)) negativos y positivos en el proceso de destitución de la presidenta Dilma Rousseff, encontrando que índice explica la rentabilidad bursátil, pero sólo en los retornos negativos y además es más atribuible al contenido del mensaje, que el volumen de Tweets. ([Silva de Souza & Silva Martins, 2022](#)). Como también una investigación que obtiene como hallazgo que la actividad en la red social Twitter en mercados emergentes predicen el retorno del día siguiente de los activos. ([Duz Tan & Tas, 2020](#)). Otro estudio encuentra que agregando el factor de noticias de redes sociales acerca del mercado, mejora el rendimiento del modelo de Fama Cahart de cuatro factores. ([Houlihan & Creamer, 2017](#))

La extensión al modelo de Fama Cahart de cuatro factores, donde incluye los índices de volatilidad VIX y V2X, además del factor construido a partir de los nuevos casos de COVID-19 a nivel mundial, el índice SP500 Twitter Sentiment, y el factor de miedo y codicia construido a partir de los movimientos de compra y ventas de la criptomoneda Bitcoin. Los datos utilizados son los índices de Chile IPSA, México BMV IPC, Colombia COLCAP y Perú SP Perú Select. Para construir los factores de riesgo originales del modelo de Fama Cahart cuatro factores, el de tamaño, ratio Book to Market, y de momemtum, se utilizan los retornos de 30 empresas listadas en el índice IPSA, retornos de 35 empresas que componen el índice BMV IPC, retornos de 18 empresas listadas en el índice COLCAP y 15 retornos de empresas listadas en el SP Perú Select. El período utilizado es entre el 03 de diciembre de 2019 y 31 de marzo de 2022, considerando retornos diarios.

Se obtiene como hallazgo que el modelo extendido a partir del modelo de Fama Cahart de cuatro factores es el modelo que tiene un mejor ajuste en términos de significancia estadística de los factores como también en cuanto al coeficiente de determinación y como un conjunto de sus variables explicativas de acuerdo con el estadístico GRS aplicado en el capítulo 4, para el periodo y para los cuatro índices que componen el mercado integrado latinoamericano (MILA). En tres mercados los estimadores de sentimiento SP500 Twitter Sentiment y de

volatilidad de la Eurozona V2X, son relevantes y estadísticamente significativos, por lo que se demuestra que estos estimadores de sentimiento y volatilidad, son relevantes para ser considerados en las estimaciones de los índices de Chile, México y Perú.

**Capítulo 7 : Incidencia de búsquedas
en internet por Google Trends, sobre
los precios de los índices de mercados
bursátiles del Mercado Integrado
Latinoamericano (MILA)**

7.1.-Resumen del capítulo

Este capítulo tiene como objetivo el análisis de la relación entre los volúmenes de búsquedas en Internet, que provee el motor del buscador de Google a través de su plataforma Google Trends, con los movimientos bursátiles de los índices que componen el MILA (Mercado Integrado Latino Americano). La motivación de esta investigación es colocar la posibilidad de una nueva línea de investigación hacia la aplicación de herramientas de la revolución de los datos, a los modelos de valoración, dejando para futuros estudios la incorporación de inteligencia artificial (IA), donde se ve una posibilidad de mejorar el rendimiento de los modelos de valoración, por medio del uso de mayor cantidad de datos y adecuados factores de riesgos, bajo redes de aprendizaje que puedan aplicar uno u otro según su aporte a la valoración.

El proceso consiste en la elección de las palabras de búsquedas desde el motor de búsquedas de Google, que pueden ser utilizados como predictores de los índices, y que puedan explicar la volatilidad en los mercados en estudio, tanto mensual como anual. Los términos predictores se obtienen por medio la utilización de la regresión LASSO, la base de datos procesada se conforma por una base adaptada de términos de búsqueda a los mercados examinados.

Las palabras de búsquedas escogidas por la regresión LASSO, que pasan a formar parte del índice de volumen de búsqueda anormal ASVA, presentan en la mayoría de los casos correlaciones positivas con la volatilidad mensual y anual calculada a través de los índices del mercado MILA. Además, esta correlación aumenta en el periodo de crisis, obteniendo también significancia estadística en ambos periodos de estudio.

Este capítulo da respuesta a la siguiente interrogante: ¿La intensidad de búsquedas en internet de términos asociados al temor en un momento determinado, tiene relación con las acciones que toman los agentes en el mercado en estudio, en la crisis sanitaria?

Como hallazgo, se obtiene que los términos de búsqueda seleccionados tienen información relevante para el mercado en particular y son candidatos para ser predictores para los índices de los países en estudio, en un modelo de valoración de activos.

7.2.-Introducción

Obtener datos acerca de la atención de los inversionistas bursátiles con respecto a los fenómenos que afectan al mercado financiero, puede considerarse como un impulsor clave en la eficiencia de un mercado en particular, debido a que refleja la confianza que tienen los inversores acerca del mercado en un periodo determinado e influye en la decisión de compra o venta de los activos en el mercado de valores. Pensar en tener esta información antes de la irrupción de Internet y principalmente de lo que se ha denominado la revolución del Big Data, era impensable, debido al costo que involucra este proceso, en caso de la utilización de encuestas y con la oportunidad de contar de este tipo de información en todo momento, es por esta razón que el comportamiento de los agentes del mercado se plantea como un supuesto en el origen de los modelos de valoración.

Los motores de búsqueda en internet hoy en día procesan millones de datos por minutos, entre ellos la consulta de términos financieros o de miedo en casos de crisis, como guerra o la pandemia del COVID-19, que pueden asociarse a un problema que puede tener efectos al entorno de las finanzas y economía en general, por lo tanto, son útiles para contar información útil para los mercados, y por consiguiente los vocablos de búsquedas se convierten en un buen proxy para obtener el comportamiento de los inversores (Preis, Moat y Stanley 2013).

La consecuencia de esta simplificación del comportamiento racional de los inversores se ha demostrado que es un error en muchos casos, desde 1980 se propuso un nuevo modelo de equilibrio competitivo basado en el equilibrio de expectativas racionales, de acuerdo con esta investigación el equilibrio se logra cuando los precios reflejan solo una parte de la información que poseen los inversionistas informados, y con este hecho a medida que aumenta el porcentaje de inversionistas informados, los precios contienen mayor información, por lo tanto, los incentivos para adquirir más información decrecen (Grossman y Stiglitz 1980)

Los inversionistas minoristas prefieren comprar acciones de empresas que tienen información, por ende, las acciones que concentran mayor atención, ya sea de noticias y análisis de los expertos tendrán más probabilidad de compra, también los inversionistas prefieren comprar las acciones que conocen frente a activos de organizaciones desconocidas o emergentes en el mercado. (Merton 1987)

En esta investigación se utilizará el motor de búsqueda Google, específicamente el servicio que provee esta empresa para obtener datos de búsquedas por países, a nivel mundial que es Google Trends. Se utiliza este motor de búsquedas, debido a que concentra la mayor cantidad de consultas a nivel mundial, a enero de 2021 representa el 85,86% de la participación de mercado en buscadores de Internet en el mundo (Statista 2022). Las consultas que se realizarán al motor de búsqueda se clasificarán en términos positivos y negativos. Existen varios estudios en el último tiempo que buscan relación entre el motor de búsquedas de Google y los mercados bursátiles, donde el volumen de consultas de Google comienza a tomar relevancia en la captura de la atención y sentimientos de los inversores (Dimpfl y Jank 2016) (Huang, Rojas y Convery 2019) (Da, Engelberg y Gao 2011) (Bijl, y otros 2016)

La búsqueda de patrones predecibles en los mercados ha sido fuente de inspiración en muchas investigaciones en finanzas. De acuerdo con la hipótesis de mercado eficiente, los precios reflejan inmediatamente en el precio la nueva información acerca del mercado (Fama, Eugene, 1970), dejando como supuesto el comportamiento de los inversionistas, donde estos ya sean minoristas o mayoristas, antes de invertir en un activo, recopilan noticias financieras al respecto. Esta búsqueda de información y de términos que van desde estilo de vida a temor de una enfermedad o conflicto entre países, cambio climático y otros temas, de alguna forma captura la atención de las personas y esta necesidad de informarse está relacionada con el sentir de las personas en un momento determinado. Esta aseveración ha demostrado en estudios y mercados que la demanda de información almacenada en los motores de búsquedas, como Google, pueden influir en distintos grados en los rendimientos de los activos o algunos casos solo en la volatilidad futura. (Da, Engelberg y Gao 2011) (Takeda y Wakao 2014) (Kim, y otros 2018), como también se ha utilizado en otras áreas como en pronosticar el precio de vehículos en un mercado emergente como lo es en Sudamérica, Chile (Carriere-Swallow y Labbé 2011)

Con la irrupción del servicio de Google Trends desde 2006, y su posterior uso como mecanismo de extraer datos sobre la atención y el sentir de los inversionistas, en diversos estudios se mostró que el índice de volúmenes de búsquedas que queda registrado en el motor se puede utilizar como proxies de sentimientos acerca de determinadas noticias (Mondria, Wu y Zhang 2010).

También se han utilizado en otras investigaciones, para realizar estudios de eventos, utilizándolos para determinar el interés de los inversores en eventos

señalados por los volúmenes de búsquedas de los agentes en un mercado en particular (Drake, Roulstone y Thornock 2012).

Estudios han encontrado relación entre los cambios en los volúmenes de búsqueda en Google y los rendimientos de acciones de una empresa en particular, utilizando la intensidad de búsquedas acerca de la empresa en periodos normales, encontrando una relación causal entre el movimiento de la acción y la intensidad de búsquedas de la empresa analizada (Vlastakis y Markellos 2012) (Preis, Moat y Stanley 2013) (Challet y Hadj Ayed 2020).

También existen estudios que buscan explicar los retornos anormales de los activos, de acuerdo con estudios de eventos o anuncios de fusiones y adquisiciones de una empresa, para establecer los efectos del SVI (Search Volume Index, construido con datos de intensidad de consultas de Google), encontrando la conexión entre SVI y los retornos del primer día después de una oferta pública inicial de la organización. (Da, Engelberg y Gao 2011)

Este capítulo, se centra en encontrar una mayor eficiencia en el mercado de valores, en periodos de crisis, ya que estas dificultades de los mercados afectan a las personas de todo el mundo, de manera directa en el caso de los inversionistas, e indirecta toda vez que estas crisis afectan al sistema económico y financiero de los países, ahora bien, una forma de ganar eficiencia en los mercados es tomar decisiones lo más informadamente posible, para afectar en menor medida a los mercados y los recursos invertidos.

En el proceso de toma de decisiones que involucra a las personas, éstas adoptarán un actuar determinado frente a las distintas noticias y/o fenómenos que ocurren en el mundo, como lo es la pandemia y la guerra en el último tiempo. Este sentir de las personas cuando interactúan con Internet, puede ofrecer una perspectiva sobre el comportamiento de los agentes en el mercado, y estos comportamientos detectados, nos pueden dar señales de advertencia tempranas en el mercado.

7.3.-Revisión de Literatura

Con la irrupción del Big Data y herramientas como Machine Learning, abre una oportunidad para generar algoritmos que pueden introducir a los modelos de valoración el sentimiento y la atención de los inversionistas, sin embargo, esta forma de obtención de datos, entendida como la carga de información que una persona hoy en día puede contar y procesar, excede fácilmente a la respuesta adecuada que puede dar una persona, por este motivo hay estudios que

atribuyen falta de atención de los agentes en el mercado (Sims 2003), lo que otros estudiosos han descrito de como este exceso de información produce de alguna forma una atención limitada, de esta forma crea una pobreza de atención y que hay formas que permiten una mejor distribución de las cargas de información (Simon 1971).

Estos aspectos de exceso de información o de falta de datos acerca del mercado terminan en muchos casos agotando la atención de los inversionistas. De acuerdo con esta limitación de la información se establece el modelo de Merton (Merton 1987), que reconoce que el inversionista tiene información incompleta al momento de tomar decisiones a pesar de la abundancia que puede tener de información. Esta incompletitud de datos acerca de los activos en el mercado tiene impacto en la fijación de los precios de las acciones. Esto trae consigo el problema que la información de cambios en los precios puede ser ignorada temporalmente por parte del mercado (Aouadi, Arouri y Teulon 2013).

En este mismo sentido, investigaciones buscando una respuesta, si la atención limitada de los inversionistas afecta a los rendimientos de los activos, encuentran como hallazgo que la falta de información si afecta al nivel de precios. (Dellavigna y Pollet 2009).

La revolución de los datos (Big Data) ha ampliado el mundo de la investigación, en el caso de las finanzas se ve como la oportunidad de ir en busca del sentimiento de las personas, específicamente de los inversionistas minoritarios, como también del componente psicológico de la economía, esto ofrece una gran posibilidad de ir experimentando el uso de estos sentimientos volcados en un motor de búsqueda, (Jun, Yoo y Choi 2018).

A continuación, se detallan una serie de estudios recientes que utilizan como fuentes de datos de Internet, ya sea por medio de motores de búsquedas, o redes sociales, que buscan eliminar el supuesto de aversión al riesgo de los inversionistas.

Los investigadores (Bui y Nguyen 2019) abordan un estudio aborda la búsqueda de los sentimientos de los inversores acerca del mercado de valores de Vietnam, utilizando términos de búsquedas extraídos desde la plataforma de Google Trends, esta estudio se plantean cuatro hipótesis: H1. La atención de los inversores a una acción específica reduce su falta de liquidez, al reducir la asimetría costos de información. H2. La atención de los inversores a todo el mercado aumenta la falta de liquidez de las acciones individuales, debido a

incertidumbre entre muchas opciones. H3. La atención de los inversores a acciones específicas reduce su volatilidad, al reducir la incertidumbre con información sobre opciones específicas. H4. La atención de los inversores a todo el mercado aumenta la volatilidad de las acciones individuales, debido a incertidumbre entre muchas opciones. En este estudio no se utilizaron términos asociados al temor u optimismo de los inversores, sino búsquedas de la empresa o acción transada en el mercado, por lo tanto, la metodología no necesita de una regresión de selección de términos de búsquedas, obtuvieron como hallazgo: un impacto significativamente positivo de la atención al mercado en su conjunto hacia las acciones, acerca de temas de falta de liquidez y volatilidad. En la misma línea de investigación a través de la búsqueda del nemotécnico de la acción que pertenecen al índice Ibovespa en Brasil, en el motor de búsqueda de Google, con la utilización de la metodología de un modelo VAR y causalidad de Granger (Pinto Ramos, Mendes Ribeiro y Scherer Perlin 2017), obtienen que el nivel de búsquedas desde Brasil y desde Estados Unidos de las acciones del índice de Brasil, afectan a variables financieras de rendimiento, la volatilidad y la negociación. Los resultados evidencian que sí es posible explicar la situación financiera brasileña basado en datos de búsqueda de Google. Otro estudio de (Costola, Iacopini y Santagiustina 2021) utilizando regresiones de corte transversal con información de Google Trends acerca de noticias del mercado de valores de países analizados, extrayendo datos desde Google Trends por área geográfica, filtrados por tópicos o términos relacionados con la pandemia del COVID-19, al igual como se realiza en este capítulo de la investigación. Obtiene como hallazgos que los volúmenes de consultas de búsqueda acerca de la pandemia en Italia, Alemania, Francia, Gran Bretaña, España y Estados Unidos están conectados con los mercados de valores. Un estudio de (Lim 2015) plantea la utilidad para el análisis técnico, para visualizar la posibles caídas o auge de un activo particular con información de intensidad de búsquedas en Google, de un activo en particular, como también para el análisis fundamental, establece que la información es útil para aplicar estudios de eventos, donde la intensidad de búsquedas puede mejorar los datos de esta metodología. El SVI (índices de volumen de búsqueda) también podría ayudar a entender mejor el nivel de interés alrededor acciones corporativas y anuncios y podría revelar ideas únicas sobre el interés y el impacto de tales noticias. (Challet y Hadj Ayed 2020) realizan una investigación utilizando la metodología de backtesting y de aprendizaje automáticos no lineales con términos de búsquedas de Google, una de las base de términos que utiliza es la base origen que utiliza esta investigación, con activos

que forman parte del SP&100. concluye que el uso de fuentes de datos, aplicadas a estudios de eventos, hace estos estudios mejoran en un 5%. Además, indican que un aumento del volumen de búsqueda en Google Trends, es difícil discernir si es a causa de una buena o mala noticia. Un estudio de ([Padungsaksawasdi y Treepongkaruna 2021](#)) utilizan la búsqueda de términos acerca del COVID-19, y sus variantes como SARS-CoV-2, Pandemia, Coronavirus, además de datos de infectados confirmados con el COVID-19 y número de muertes a causa del COVID-19, al igual como se utilizan estos datos en esta tesis doctoral. La metodología se utiliza por medio de regresiones con índices de 71 países revisando la relación de causalidad entre los índices bursátiles y el volumen de búsqueda de Google (SVI). Encuentran que tanto la utilización de SVI, como el crecimiento de los casos de Covid-19, bajan el rendimiento de los activos en los países analizados. Además de encontrar que cuando aumentan los casos confirmados de Covid-19, los inversionistas minoristas buscan más información, mejorando los rendimientos de los índices bursátiles durante el brote de la pandemia. ([Xu, Zhang y Shen 2022](#)) realizan un estudio en el mercado de valores de China, donde primero someten a la serie de datos a la prueba de Dickey Fuller Aumentada y causalidad de Granger, revisando también los gráficos de impulso respuesta de los retornos e intensidad de búsquedas desde Google Trends. Obtienen como conclusiones, que cuando las personas se enfrentan a la incertidumbre, a menudo recurren a motores de búsqueda de Internet. La investigación utiliza un índice de incertidumbre, donde refleja el sentimiento de los inversionistas a partir de datos del motor de búsquedas, con miras de establecer una relación entre el mercado de valores y el sentimiento de los inversionistas, encuentran causalidad y permite prevenir una fuerte volatilidad en el mercado de valores, permitiendo mejorar la toma de decisiones en políticas públicas. ([Dey, y otros 2022](#)) en la misma línea de investigación, utiliza la intensidad de búsqueda extraída desde Google Trends de acciones que componen el SP&500, las preguntas que se hacen en su investigación son las siguientes: ¿Cómo podemos cuantificar la dinámica de propagación local de COVID-19 y hacer la propagación local, por ejemplo, la propagación a nivel de condado de EE. UU. de COVID-19, afectan los precios de las acciones?, ¿El número de casos y muertes de COVID-19 influye en los precios de las acciones?, ¿La propagación local, la cantidad de casos de COVID-19 y las muertes influyen en la volatilidad del mercado de valores?, ¿Los volúmenes de búsqueda de Google relacionados con COVID-19 muestran alguna relación con el precio de las acciones y la volatilidad?, ¿La propagación local de COVID-19, la cantidad de

casos y muertes y los volúmenes de búsqueda de Google transmiten algún dato adicional?. Utilizando modelos de aprendizajes obtienen como conclusión que: que mejoras al agregar esta información, sobre todo en los rendimientos anormales del mercado a largo plazo.

Con respecto al sentimiento del mercado frente a la pandemia ([Guan, Liu y Cheng 2022](#)), realizan una investigación de retornos bursátiles diarios de una muestra de 1619 empresas, pertenecientes a 34 sectores económicos de países que son parte de la OECD (La Organización para la Cooperación y el Desarrollo Económico), mediante la utilización de autorregresión vectorial aumentada. Los resultados que se obtienen es que los sentimientos registrados y clasificados desde redes sociales, impactan significativamente a los movimientos de los precios de los activos, antes y durante la caída de del mercado por causa del COVID-19, demuestra de cómo la intensidad digital mitiga el efecto negativo de una crisis en el rendimiento de las acciones en el mercado. Bajo este mismo análisis de investigar como incorporar el sentir de los agentes del mercado, aplicando la intensidad de búsquedas a empresas por sectores industriales ([Ding, y otros 2020](#)) analizan una muestra de 1567 empresas pertenecientes a 37 sectores industriales, con datos diarios. Y con intensidad de búsquedas extraídas desde Google Trends, con términos acerca del COVID-19. Se aplica la metodología VAR (Vectores Autorregresivos), concluyendo que existen efectos significativos en los precios de los activos que pertenecen a distintos sectores industriales.

Un estudio realizado por ([Díaz y Henríquez 2021](#)), utilizando dos índices bursátiles de Chile IPSA e IGPA, además del SP&500 de estados unidos, aplicado en un período de pandemia y focalizado en cómo se comporta el sentir de los inversores en las cuarentenas aplicadas por la pandemia. Con utilización de la metodología de estudio de eventos y datos de panel, encontramos que los indicadores indirectos de las redes sociales. Obtienen que el sentimiento basado en las consultas de Twitter está relacionado negativamente (más pesimista) con aumentos en el número de personas confinadas, pero con un efecto estadísticamente significativo concentrado en personas de las cohortes más ricas de la población. Para indicadores de sentimiento social basados en Google Trends, se encuentra que la intensidad de la búsqueda durante los períodos relacionados con el gobierno anuncios se relaciona positivamente con aumentos en el número total de personas confinadas, sin embargo, este efecto no parece depender de los segmentos de la población afectados. por la cuarentena. Además, tienen como hallazgo que la heterogeneidad observada en el sentimiento refleja

heterogeneidad en las reacciones del mercado de valores a los anuncios del gobierno. Proporcionamos evidencia de que el comportamiento del mercado de valores observado en torno a los anuncios de cuarentena puede explicarse por el número de personas de los segmentos más ricos de la población que ingresan o salen del confinamiento. Otro estudio de ([Eichenauer, y otros 2022](#)), aplicando un estudio de eventos, comparando con variables macroeconómicas de Alemania y Austria, obteniendo el sentir de las personas o temor hacia la pandemia del COVID-19, extrayendo datos desde Google Trends, descubren que los datos diarios no capturan las tendencias a largo plazo, indican que este problema ha pasado desapercibido en la literatura acerca de buscar el comportamiento de los agentes del mercado. Además, que el ruido puede ser sustancial en las conclusiones de los investigadores.

([Eachempati, Srivastava y Panigrahi 2021](#)) utilizan un enfoque de aprendizaje automático de Twitter, identifican antes que las ilustra que las palabras "covid", "enero", "virus", "muertes" y "pandemia" son las más utilizadas por las personas desde que se detectó el virus por primera vez en enero con un potencial impacto disruptivo en la sociedad y las empresas. Para analizar y seguir el sentimiento de los inversores que ha llevado al mercado a un nuevo mínimo durante los primeros 150 días de la era COVID-19. El único respiro para la recuperación de los mercados financieros es la reducción de los casos infectados por COVID-19 por el momento hasta que se desarrolle una vacuna para el virus. Con datos de mercados de EE.UU., Reino Unido, China e India. Encuentran que un sentimiento altamente negativo en Twitter tiene una relación directa de impacto negativo en los mercados de valores.

También existen detractores con la utilización de datos que provienen desde la intensidad de búsquedas en internet como la investigación de ([Cebrián y Domenech 2022](#)) Google Trends se ha convertido una fuente de datos popular entre los investigadores, debido a contener información del sentir de las personas en una gran variedad de temas. En economía, su principal utilización ha sido para pronosticar el turismo, demanda, desempleo o ventas. Esta investigación cuestiona la calidad de estos datos, Lo que se descubre es que algunos problemas de precisión de la medición de GT, lo que potencialmente afecta los resultados, esta falta de precisión podría convertirse en una fuente importante de sesgo, si no se corrige y cuando estos datos son utilizados para estimar modelos econométricos, puede afectar a las estimaciones, que pueden conducir a la toma de decisiones o políticas equivocadas.

Estudios realizados antes de pandemia, que buscan probar factores de riesgo exógenos para incorporar el sentir de los inversionistas:

(Ahmed, y otros 2017), realizan una investigación que plantea lo siguiente: Las decisiones financieras se encuentran entre las decisiones más importantes que cambian la vida de las personas. Existe una fuerte correlación entre la toma de decisiones financieras y el comportamiento humano. La investigación se centró en la relación de lo que piensa la gente y como se mueve el mercado de valores. Analizan los datos de 2010 a 2015, identificando eventos empresariales, políticos y financieros que impactan directamente al mercado de valores de Pakistán. Los datos de comportamiento humano se obtienen desde Google Trends. Encontrando que el aumento en la búsqueda de estos temas puede conducir a la caída o alza del mercado de valores. Una investigación de (Lai, y otros 2021) Investigación que examina si el índice de volumen de búsqueda de Google (GSVI), como proxy de la atención del inversionista, para verificar si puede predecir el exceso de retorno y los retornos anormales en el mercado de valores de Taiwán, utilizando un periodo de septiembre de 2016 a agosto de 2019, aplicado a 48 empresas de ese mercado, con periodicidad diaria. Además, para las regresiones y prueba de intensidad y búsquedas de las empresas, se utiliza el modelo de valoración de Fama y French de cinco factores (Fama & French, 2015), obtienen como hallazgo que los datos con un rezago del GSVI afectan negativamente a los retornos de los activos. (Pierre, y otros 2019) realiza un estudio que presenta una metodología para la utilización de los índices de búsqueda de Google, desde el sitio de búsquedas de Google Trends, para medir el interés de los inversionistas potenciales en las acciones que figuran en el índice Dow Jones. Descubre que, aproximadamente el 43% de las veces, la estrategia basada en el aprendizaje automático superó a la estrategia comercial de referencia, lo que indica que, de hecho, existe una correlación entre los movimientos de precios de ciertos activos en el Dow Jones y la cantidad de búsquedas en Google sobre estos activos. (Bustamante, Hernández del Valle y Ortiz Ramírez 2019), realizan una investigación acerca del motor de búsqueda de Google para pronosticar la volatilidad de corto plazo, entre el tipo de cambio entre el peso mexicano y dólar de Estados Unidos. Se revisa las investigaciones que han utilizado Google Trends para examinar variables explicativas. Concluyendo que tener en cuenta la variable Google Trends ayuda a explicar parcialmente el comportamiento de la volatilidad; y es necesario incorporar más niveles de agregación de términos de búsquedas acerca de un mercado en particular. (Curme, y otros 2013), utiliza en un análisis de los datos históricos de

2004 hasta 2012, nos basamos en registros del buscador Google y la enciclopedia en línea Wikipedia, así como juicios del servicio Amazon Mechanical Turk. Encontramos evidencia de enlaces entre búsquedas en Internet relacionadas con la política o los negocios y posteriores movimientos bursátiles. En particular, encontramos que un el aumento en el volumen de búsqueda de estos temas tiende a preceder al stock cae el mercado. Los autores sugieren que las extensiones de estos análisis podrían ofrecer información sobre el flujo de información a gran escala antes de una serie de eventos del mundo real. En particular, da cuenta que un el aumento en el volumen de búsqueda de estos temas tiende a preceder a la caída del mercado. Se sugiere que las extensiones de estos análisis podrían ofrecer información sobre el flujo de información a gran escala ante de una serie de eventos del mundo real. (Pai, Hong y Lin 2018) establecen el potencial del marco propuesto para previsión de los mercados de valores. Dado que las palabras clave de Google Trends afectan significativamente la precisión del pronóstico. La selección de palabras clave da como resultado diferentes conjuntos de datos para el análisis y así genera diferentes resultados numéricos. Este estudio proporciona tres formas, a saber, las definiciones de los usuarios, búsquedas de tendencias de Google Trends y tweets, para determinar palabras clave para Google Trends. A futuro las palabras clave registradas en Google Trends opción esencial para valorar activos. (Pai, Hong y Lin 2018) Estudian los datos comerciales históricos, que generalmente están asociados a la causalidad financiera y que teóricamente han sido ampliamente utilizados, para la predicción de los precios en el mercado de valores. Con el surgimiento de las redes sociales y las herramientas de búsqueda en Internet, la importancia de las relaciones de datos se ha ampliado. El objetivo de la investigación es revisar el desempeño de los pronósticos de los mercados bursátiles a partir de los datos de Google Trends, datos históricos del mercado, y Tweets desde la red social Twitter. Utilizando la técnica de selección de características (CFS), se utiliza para seleccionar predictores (variables independientes), obteniendo como resultado que el uso de datos híbridos a partir de la tendencia de búsqueda y comentarios de Internet, son una alternativa prometedora para pronosticar los precios en el mercado de valores. (Fauzi, y otros 2019) Una investigación que aplica el modelo de Fama French de tres factores para probar la relación entre la atención de los inversores y el rendimiento de las acciones. El estudio encontró que el volumen de búsqueda de Google capta la atención de compra a corto plazo y este aspecto genera un mayor rendimiento. Sin embargo, un aumento en el volumen de

búsqueda de Google no logra reducir la asimetría de información que lleva a un aumento de liquidez.

7.4.-Metodología y datos

En la figura 7.1, se puede apreciar la secuencia de la metodología utilizada en esta investigación. En primer paso es la selección de términos de búsqueda, se utilizan los términos utilizados en otros trabajos de investigación con adaptaciones (Preis, Moat y Stanley 2013), propias de acontecimientos o de aspectos culturales de los países sometidos en el estudio, posteriormente se extraen los volúmenes de búsquedas desde Google Trends, en este caso se utilizan datos de cinco años con frecuencia semanal.

Posteriormente, se obtienen los precios de los índices con misma frecuencia semanal, de los índices IPSA (Chile, BMV IPC (México), COLCAP (Colombia) y SP Perú Select (Perú).

En la tabla 7.1, se muestran los términos utilizados en el trabajo de investigación de (Preis, Moat y Stanley 2013) en Estados Unidos, en el cual utilizaron palabras claves relacionadas con los mercados financieros antes de que caiga el mercado de valores. En la tabla 7.2, se muestran términos agregados a la base y algunos reemplazados, como NYSE por los índices que componen el MILA.

han sido explotados en la construcción de estrategias comerciales rentables.

ID	Term	ID	Term	ID	Term	ID	Term	ID	Term	ID	Term
1	debt	19	religion	37	finance	55	war	73	bubble	91	crash
2	color	20	investment	38	car	56	oil	74	politics	92	dividend
3	stocks	21	marriage	39	fed	57	gain	75	energy	93	short
4	restaurant	22	society	40	metals	58	default	76	conflict	94	selling
5	economics	23	headlines	41	house	59	economy	77	financial	95	consume
6	portfolio	24	stock	42	risk	60	short	78	markets	96	home
7	housing	25	market	43	rich	61	sell	79	trader	97	garden
8	credit	26	bonds	44	water	62	gains	80	buy	98	train
9	revenue	27	office	45	crisis	63	movie	81	opportunity	99	transaction
10	inflation	28	invest	46	holiday	64	earnings	82	rare	100	forex
11	dow jones	29	cash	47	derivatives	65	food	83	earths	101	labor
12	return	30	loss	48	nasdaq	66	nyse	84	lifestyle	102	fun
13	markets	31	fine	49	chance	67	buy and hold	85	greed	103	environment
14	unemployment	32	happy	50	travel	68	arts	86	world	104	ring
15	growth	33	sell	51	leverage	69	health	87	freedom		
16	hedge	34	banking	52	returns	70	culture	88	fond		
17	money	35	ore	53	gold	71	tourism	89	consumption		
18	cancer	36	profit	54	success	72	present	90	kitchen		

Tabla 7.1: Base de términos utilizados: Fuente: (Preis, Moat y Stanley 2013)

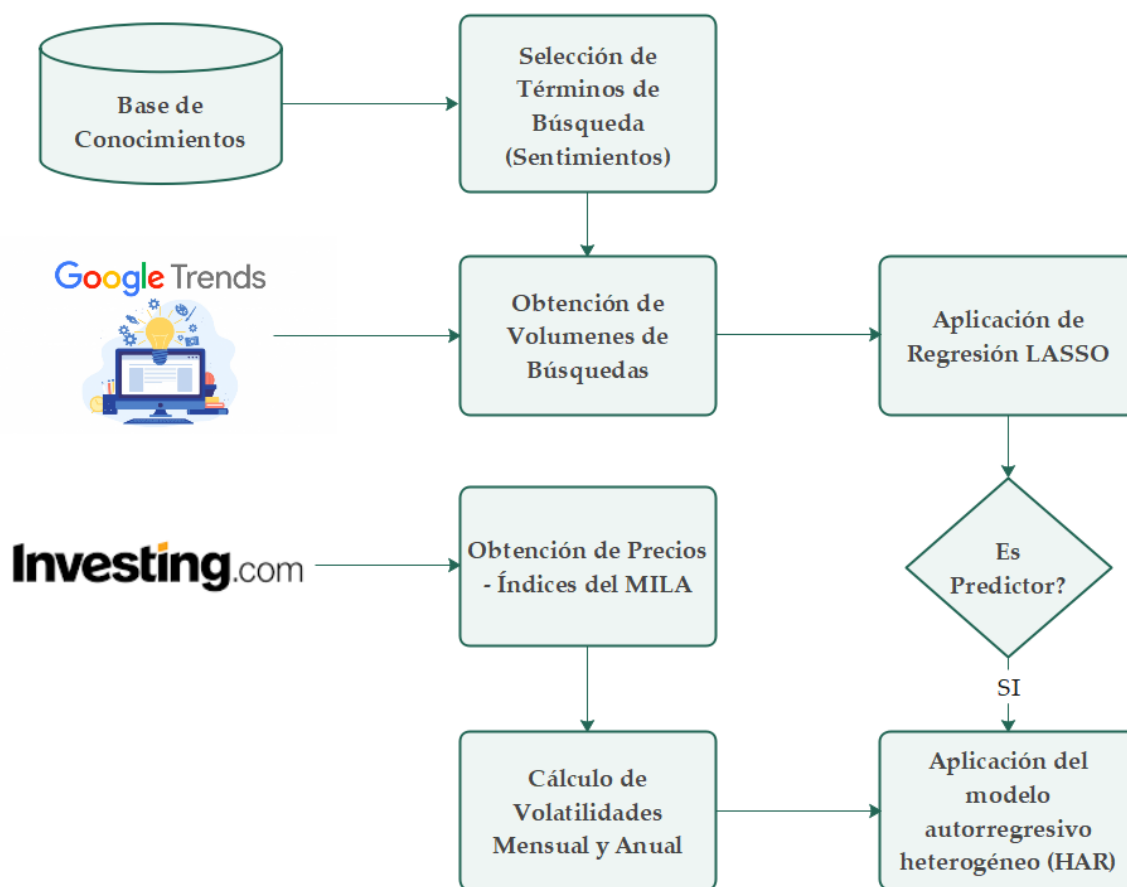
ID	Term	ID	Term	ID	Term
1	austeridad	11	estallido social	21	automóvil
2	impuestos	12	pensiones	22	metales
3	tasa de interés	13	AFP	23	crecimiento económico
4	precio del oro	14	sequia	24	riqueza
5	pobreza	15	drogas	25	PIB
6	precio del cobre	16	narcotráfico	26	emprendimiento
7	Covid	17	delincuencia	27	IPSA
8	riesgo país	18	arriendo	28	COLCAP
9	caída de la bolsa	19	playa	29	BMV IPC
10	recesión	20	bolsa de Valores	30	SP PERU SELECT

Tabla 7.2: Términos de adaptación a mercados latinos, se adicionan a base anterior

Para determinar si las variables independientes (términos de búsqueda) seleccionados para el estudio son predictores adecuados, se someterán a la regresión LASSO, que es un modelo lineal que penaliza el vector de coeficientes. Tiende a generar coeficientes dispersos que toman el valor cero, esto quiere decir que el modelo va a ignorar algunas de las características predictivas, lo que puede ser considerado un tipo de selección automática. Este proceso se ha llevado a cabo en otros estudios en periodos recientes al igual como se aplicará en la presente investigación (Lyócsa, y otros 2020).

Luego se calculará la volatilidad mensual y anual de los mercados de valores de los países del MILA, una vez que se calculan las volatilidades de los índices de los mercados de valores, se estiman tres modelos con la versión simplificada del autorregresivo heterogéneo (HAR) (Corsi 2009), estimados mediante mínimos cuadrados ordinarios, se busca la significancia estadística de los estimadores.

Figura 7.1: Metodología de la investigación, Fuente: Elaboración Propia.



7.4.1.-Google Trends

Google Trends (GT) es un servicio en línea disponible gratuitamente proporcionado por Google, que permite a los usuarios de Internet analizar el volumen relativo de búsqueda de diferentes términos de búsqueda. Los resultados se remontan al 01 de enero de 2006 y se pueden desglosar por países, regiones, ciudades e idioma. En tabla 7.1 se muestran los términos de búsquedas que se van a solicitar a Google Trends, existen adaptaciones a los términos indicados por un estudio anterior (Preis, Moat y Stanley 2013)

Términos de búsqueda Sentimiento Negativos		Términos de búsqueda Sentimiento Positivos	
deuda	tasa de interés	arriendo	ganar
crédito	crisis	acciones	vacaciones
religión	precio del oro	restaurante	riqueza

cáncer	desempleo	portafolio	éxito
pérdida	pobreza	alojamiento	estilo de vida
dinero	inflación	ingresos	mercados financieros
vender	precio del cobre	mercados	película
default	guerra	retorno	arte
agua	Covid	crecimiento	cultura
riesgo	riesgo país	cobertura	comprar
petróleo	paro	casamiento	turismo
economía	caída de la bolsa	bonos	consumir
venta corta	recesión	derivados	libertad
codicia	estallido social	ganancia	cocina
alimento	pensiones	playa	mano de obra
mineral	AFP	bienes	diversión
salud	dinero	bolsa de Valores	consumo
burbuja	sequia	bancario	crédito
política	drogas	feliz	PIB
energía	narcotráfico	automóvil	dividendos
conflicto	delincuencia	finanzas	beneficios
divisas		invertir	inversión
medio ambiente		casa	emprendimiento
austeridad		metales	IPSA
impuestos		viaje	COLCAP
		crecimiento económico	BMV IPC
			SP PERU SELECT

Tabla 7.3: Términos de búsqueda en Google Trends

7.4.2.-Search Volume Índices (SVI)

Los resultados de Google Trends vienen en forma de frecuencias de búsqueda relativas o índices de volumen de búsqueda (SVI), en lugar de las frecuencias de búsqueda absolutas. El SVI de una palabra en un momento t es un entero entre 0 y 100 y se calcula como el volumen de búsqueda en el tiempo t de una palabra (V_t), dividido por el volumen máximo de búsqueda V_{max} de esa palabra durante

un período de tiempo Δt . Para el resto de esta investigación, el SVI en un momento t estará representado por nt :

$$SVI = nt = \frac{V_{i,t}}{V_{\max_{i,\Delta t}}} \quad 7.1$$

Donde: $SVI = nt$: Corresponde al resultado del término de búsqueda, de acuerdo con el volumen máximo obtenido en el período de consulta, $V_{i,t}$: Corresponde al volumen del término i en tiempo t , $V_{\max_{i,\Delta t}}$: Corresponde al ponderador máximo del término i de búsqueda en el periodo consultado.

Para realizar un índice general de los términos de búsqueda, se opta por un promedio simple de todos los índices individuales para cada semana t .

$$ASVI_t = \frac{\sum_{i=1}^t V_{i,t}}{N} \quad 7.2$$

Donde: $ASVI_t$: Corresponde al Average Search Volumen Index en periodo t , $V_{i,t}$: Corresponde a la variable del término de búsqueda i en el período t , N : Cantidad total de términos de búsqueda en Google Trends.

Para el estudio acerca de cómo los patrones cambiantes en la actividad de búsquedas están relacionados con la incertidumbre del mercado, se calcula el volumen de búsqueda anormal (Da, Engelberg y Gao 2011):

$$ASVA_t = \ln \left(\frac{ASVI_t}{\text{mediana}[ASVI_{t-1}, \dots, ASVI_{t-5}]} \right) \quad 7.3$$

Donde: $ASVA_t$: Corresponde a Abnormal Search Volume Activity en período t , $ASVI_t$: Corresponde al Average Search Volumen Index en periodo t

Para analizar períodos de crisis, debido a la velocidad y consecuencias de las crisis, como la de pandemia, el indicador ASVA se considerará como el indicador de pánico y miedo. Cuanto mayor sea el valor de ASVA mayor será el interés de las personas en los términos relacionados con las crisis.

Para obtener el índice $ASVI_t^{\text{Global}}$ y el correspondiente $ASVA_t^{\text{Global}}$, se obtiene con el promedio de los indicadores locales del resto de los países, por ejemplo, para obtener $ASVI_t^{\text{Global}}$ de Chile se toma el promedio de $ASVI_t^{\text{Local}}$ de los otros países latinoamericanos MILA.

En Google Trends también es posible ingresar más de un término de búsqueda a la vez. Si se realiza la búsqueda de esta forma, el resultado que obtiene cada

palabra se compara con el valor más alto de todas las palabras ingresadas de acuerdo con la frecuencia de tiempo solicitada al buscador de tendencias, que corresponde al período Δt .

Para obtener la variación de cada término de búsqueda de Google Trends, se utiliza la siguiente ecuación

$$\Delta \ln(V_{t+1}) = \ln(V_{t+1}) - \ln(V_t) \quad 7.4$$

Donde: $\ln(V_{t+1})$, Corresponde al logaritmo natural del término de búsqueda en el periodo t+1 y $\ln(V_t)$, es el término de búsqueda en el período t.

Con respecto a los precios de las bolsas de valores de los países que componen el MILA (IPSA, BMV SP, COLCAP, SP PERU SELECT) se utilizan los cierres semanales de cada índice, para obtener los retornos a partir de los precios, se utilizará la siguiente ecuación:

$$\text{Ret}_t = \ln\left(\frac{P_t}{P_{t-1}}\right) \quad 7.5$$

Para medir la incertidumbre en el mercado, se utilizará la varianza diaria de los rendimientos del mercado, calculado a partir de los datos de alta variabilidad. Cuanto mayor sea la varianza, mayor será la incertidumbre del mercado. Esta varianza se modelará de acuerdo con la siguiente fórmula:

$$RV_t = 52 \times (j_t^2 + \sum_{t=1}^M r_{i,t}^2) \quad 7.6$$

Donde: 52: Corresponde a las semanas del año, $r_{i,t}$: $100\% \times (\ln P_{i,t} - \ln P_{i,t-1})$, $j_t = 100 \times (\ln P_{i,1} - \ln P_{i,1-M})$, es la rentabilidad entre el valor de cierre del índice el día t - 1 y el valor de apertura el día t

7.4.3.-Proceso de selección de términos de búsquedas relevantes

Una vez obtenidos los datos, tanto de volúmenes de búsqueda estandarizados, se aplicará la regresión LASSO (Least Absolute Shrinkage and Selection Operator) (Tibshirani 1996), debido a que los términos de búsquedas planteados son variados y cada uno puede inferir en distinto grado a los índices en estudio,

se utilizará para poder determinar que termino es un estimador adecuado para el índice analizado. Un modelo de regresión lineal, penalizado – LASSO, penaliza la suma de los valores absolutos de los coeficientes de regresión:

$$\|\beta\|_1 = \sum_{j=1}^p |\beta_j| \quad 7.7$$

Esta penalización tiene el efecto de forzar a que los coeficientes de los predictores tiendan a cero. Dado un predictor con coeficiente de regresión cero no influye en el modelo. Lasso consigue excluir los estimadores menos relevantes, el grado de penalización está controlado por el hiper parámetro λ , cuando $\lambda = 0$, el resultado es equivalente al de la regresión de modelo por mínimos cuadrados ordinarios (MCO). A medida que λ aumenta, mayor es la penalización y más predictores quedan excluidos:

$$\sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^p \beta_j^2 = \text{Suma Residuos Cuadrados} + \lambda \sum_{j=1}^p \beta_j^2 \quad 7.8$$

Para generar una regresión LASSO en cada índice del mercado MILA, primero se deben determinar los valores de dos parámetros α y λ . $\alpha = 1$ indica el uso del método LASSO. Para seleccionar λ para cada ajuste, se ejecuta una validación cruzada de 10 veces, esta es una técnica de validación de modelos para estimar la precisión de la predicción, y luego se elige un valor λ que no solo conduce a error pequeño de predicción, sino que también dirige el método LASSO, para seleccionar un número razonable de predictores.

7.4.4.-Modelo para estimar por la regresión LASSO

El objetivo de esta investigación es revisar el potencial cuantificado de poder predictivo de los datos que provienen del motor de búsqueda de Google, con tendencias de acuerdo con palabras claves definidas para los mercados que conforman el MILA, el modelo a procesar para obtener predictores de los indicados anteriormente como volumen porcentual de búsqueda por semana.

$$\text{Reg}_{\text{Lasso}} = \text{Retorno Índice}_i + \alpha_i + \text{Termino}_1 + \text{Termino}_2 + \dots + \text{Termino}_n \quad 7.9$$

Los mercados que se analizaran son de países latinoamericanos (Chile, Colombia, México y Perú), son mercados más pequeños en términos bursátiles y en vías de

desarrollo, los términos de búsquedas se aplicarán a cada país, donde se obtendrán datos semanales que corresponde a cada país, y se consolidarán los términos que coincidan en los países. El periodo de datos semanales comprende desde el 14 de mayo de 2017 a 01 de mayo de 2022, se revisará el periodo completo y el periodo de crisis sanitaria comprendido entre octubre de 2019 a mayo de 2022

Para obtener índices locales y globales de los países en estudio se realiza un índice global de términos de búsquedas $ASVI_t^{Global}$, como también el índice de búsqueda anormal $ASVA_t^{Global}$, estos índices representan la intensidad de volúmenes de búsquedas de los países sometidos al estudio. Para la obtención de estos índices globales corresponderá al promedio de $ASVI_t^{Local}$ y $ASVA_t^{Local}$, de los cuatro países considerados en la investigación

El siguiente proceso se utilizará de acuerdo con un estudio realizado en economías desarrolladas (Lyócsa, y otros 2020):

El primer modelo que se utilizará para la estimación de los modelos y prueba de estimadores será una versión simplificada del modelo autorregresivo heterogéneo (HAR), estimado por medio de mínimos cuadrados ordinarios (MCO). El modelo de referencia es:

$$\ln RV_{t+1} = \beta_0 + \beta_1 \ln RV_t^M + \beta_2 \ln RV_t^A + \mu_t \quad 7.10$$

Donde: $\ln RV_{t+1}$ Corresponde a la volatilidad del índice bursátil en el período t+1, $\ln RV_t$: Corresponde a la volatilidad del índice bursátil en el período t, $\ln RV_t^M$: Corresponde a la volatilidad mensual calculado de la siguiente forma (Corsi 2009):

$$RV_t^M = \frac{1}{4} (RV_t^w + RV_{t-1w}^w \pm \dots + RV_{t-3w}^w) \quad 7.11$$

Y para la volatilidad anual se utilizará la siguiente forma:

$$RV_t^A = \frac{1}{12} (RV_t^M + RV_{t-1w}^M \pm \dots + RV_{t-11M}^M) \quad 7.12$$

Se utiliza la especificación logarítmica para obtener el sesgo positivo de la varianza, y los estimadores β_1 y β_2 se pueden interpretar como el porcentaje de cambio entre RV_{t+1} dado un cambio de 1% en RV_t , para determinar la elasticidad.

El segundo modelo agrega el volumen de búsqueda anormal local

$$\ln RV_{t+1} = \beta_0 + \beta_1 \ln RV_t^M + \beta_2 \ln RV_t^A + \beta_3 \ln ASVA_t^{Local} + \mu_t \quad 7.13$$

Donde: $\ln ASVA_t^{Local}$: Corresponde al volumen de búsqueda anormal por país en tiempo t.

El tercer modelo agrega el volumen de búsqueda anormal global:

$$\ln RV_{t+1} = \beta_0 + \beta_1 \ln RV_t^M + \beta_2 \ln RV_t^A + \beta_3 \ln ASVA_t^{Global} + \mu_t \quad 7.14$$

Donde: $\ln ASVA_t^{Global}$: Corresponde al volumen de búsqueda anormal promedio de los cuatro países en estudio en tiempo t.

7.5.-Resultados

La Tabla 7.2, muestra los coeficientes de la regresión LASSO en los índices del MILA, en el periodo completo de estudio, y la Tabla 7.3 muestra los coeficientes de la regresión LASSO considerando el período de crisis. Los términos mostrados en las tablas son los sugeridos por la regresión LASSO, como términos que aportan información importante para influir en los rendimientos los índices del MILA, en periodo completo y el periodo que solo considera crisis sanitaria y guerra.

Para entender el impacto que sugieren los coeficientes, por ejemplo, el coeficiente correspondiente al término covid de -0,0308, en periodo completo, significa que, controlando las otras variables, un aumento de 1 unidad en el volumen de búsqueda estandarizada de Google de la palabra "covid" corresponde a una disminución de -0,0308 unidades en el retorno semanal del IPSA, en frecuencia semanal.

En el periodo completo, los términos que tienen efecto positivo en el IPSA son: "crédito", "vender", "impuestos", "sequía", "casa", "viaje", "consumir", "cocina", "inversión", y "emprendimiento". "crédito" frecuentemente se puede asociar a una crisis financiera, pero tiene un efecto positivo hacia el índice, lo que puede implicar que se tengan mayor acceso a crédito por parte de las personas y empresas, en el caso de "vender", "impuesto" y "sequía", tienen un impacto positivo en el índice, puede inferirse que son oportunidades que ven las personas y empresas. El término "casa" está directamente relacionado con el crecimiento

real del mercado de valores. Los demás términos de búsquedas positivos infieren directamente en el mercado de “inversión” y “emprendimiento” y el resto en el estilo de vida en tiempos de bonanza.

Los términos que afectan negativamente al índice en el periodo completo son: “crisis”, “precio del oro”, “precio del cobre”, “covid”, “AFP”, “acciones”, “bonos”, “bolsa de valores” y “riqueza”, donde los términos son relevantes en relación con aportar rendimiento negativamente al IPSA. El término de la pandemia y “AFP” en Chile son las administradoras de fondos de pensiones, que además de invertir parte de los fondos de trabajadores en el mercado de valores chileno, se han visto en cuestionamiento por lo bajo de las pensiones que están otorgando a los pensionados, los demás términos de búsquedas están asociados directamente al mercado de valores.

Con respecto a los términos de México, al igual que Chile, el término “Covid” obtiene coeficiente negativo, con mayor coeficiente obtiene el término “Dinero”. En los términos de Colombia también aparece el término “Covid” al igual que los países anteriores como coeficiente negativo, aparecen términos financieros y de “Petróleo”, por último, Perú da como resultado términos relacionados al estilo de vida, seguridad y financieros.

Termino de Búsqueda Chile	Coef.	Termino de Búsqueda México	Coef.	Termino de Búsqueda Colombia	Coef.	Termino de Búsqueda Perú	Coef.
(Intercepto)	0,0002	(Intercepto)	0,0002	(Intercepto)	0,0007	(Intercepto)	0,0010
Crédito	0,0090	Dinero	0,0353	Petróleo	-0,0026	Playa	0,0405
Vender	0,0100	Covid	-0,0290	Desempleo	0,0092	Derivados	0,0008
Impuestos	0,0022	Recesión	-0,0023	Covid	-0,0669	Delincuencia	-0,0035
Crisis	-0,0087	Alojamiento	0,0003	Acciones	-0,0093	Cultura	-0,0085
Precio del oro	-0,0004	Bancario	0,0037	Bonos	0,0056	Cocina	-0,0702
Precio del cobre	-0,0066			Beneficios	0,0042	Cobertura	0,0102
Covid	-0,0308					Casamiento	0,0008
AFP	-0,0020					Bolsa de Valores	-0,0051
Sequía	0,0045					Bienes	-0,0093
Acciones	-0,0163						
Bonos	-0,0054						
Bolsa de Valores	-0,0028						

Casa	0,0166
Viaje	0,0070
Riqueza	-0,0013
Consumir	0,0113
Cocina	0,0038
Inversión	0,0038
Emprendimi ento	0,0032

Tabla 7.4: Resultado de Coeficientes de términos no excluidos en regresión LASSO, período completo de estudio. Software utilizado Rstudio.

En el periodo de crisis, que muestra la tabla 7.2, los términos que inciden positivamente en el índice IPSA son: “deuda”, “crédito”, “dinero”, “vender”, “medio ambiente”, “guerra”, “sequia”, “crecimiento”, “cobertura”, “finanzas”, “consumir”, “libertad”, “beneficios” e “inversión”. Los términos que llaman la atención que aporte información en términos positivos al índice son “deuda”, tiene un efecto positivo en el análisis del mercado chileno, posiblemente porque más "deuda" también puede indicar una mayor capacidad de pago, el término “guerra”, aporta un coeficiente positivo, se puede inferir en Chile por el aumento de precio de los minerales, ya que, en estos conflictos, aumenta el precio de los metales. El término libertad obtiene un impacto positivo en el índice, es un término muy utilizado en el país últimamente desde el estallido social y el proceso de nueva constitución que se está viviendo a partir de la crisis social. Revisando los términos de búsqueda que obtienen coeficientes negativos son: “cáncer”, “riesgo”, “precio del oro”, “precio del cobre”, “covid”, “AFP”, “acciones”, “retorno”, “bonos”, “bolsa de valores”, “bancario” y “riqueza”.

En el periodo de crisis obtienen relevancia en el índice IPSA, la mayoría términos de búsquedas financieros económicos y dos asociados a salud.

Revisando los términos resultantes como predictores de México, los predictores que obtienen coeficientes negativos son relacionados con energía y financieros, positivos aparecen términos relacionados con finanzas y de estilo de vida.

En el caso de Colombia, los términos con coeficiente negativo aparecen términos relacionados con commodities, “Covid” y “Acciones”.

Por último, Perú que amplia en gran medida los términos como predictores en el período de crisis que obtienen coeficientes negativos están asociados a finanzas, estilo de vida, problemas sociales y políticos, con respecto a los coeficientes

positivos, se encuentran términos de estilo de vida, finanzas, “Energía” y “Medio Ambiente”.

Término de Búsqueda Chile	Coef.	Termino de Búsqueda México	Coef.	Termino de Búsqueda Colombia	Coef.	Termino de Búsqueda Perú	Coef.
(Intercepto)	0,0005	(Intercepto)	0,0012	(Intercepto)	0,0005	(Intercepto)	0,0010
deuda	0,0096	Dinero	0,0624	Crédito	0,0555	Tasa de Interés	0,0121
crédito	0,0240	Petróleo	-0,0003	Petróleo	-0,0048	Vender	0,0205
cáncer	-0,0103	Venta corta	0,0005	Precio del oro	-0,0017	Venta Corta	0,0068
dinero	0,0027	Covid	-0,0289	Desempleo	0,0057	Viaje	-0,0541
vender	0,0257	Recesión	-0,0039	Covid	-0,0691	Retorno	-0,0089
riesgo	-0,0311	Alojamiento	0,0028	Acciones	-0,0214	Religión	0,0028
medio ambiente	0,0099	Cobertura	0,0063	Bonos	0,0107	Petróleo	-0,0158
precio del oro	-0,0095	Playa	0,0021	Bancario	0,0067	Drogas	-0,0014
precio del cobre	-0,0190	Bolsa de valores	-0,0104			Energía	0,0251
guerra	0,0007	Bancario	0,0151			Estilo de Vida	0,0052
covid	-0,0227	Finanzas	0,0087			Feliz	-0,0058
AFP	-0,0055	Vacaciones	0,0002			Finanzas	0,0048
sequia	0,0166	Consumir	0,0007			Ganar	0,0158
acciones	-0,0284	PIB	-0,0020			Libertad	-0,0637
retorno	-0,0013					Medio Ambiente	0,0278
crecimiento	0,0200					Película	-0,0476
cobertura	0,0040					Pensiones	-0,0029
bonos	-0,0100					PIB	-0,0049
bolsa de valores	-0,0034					Playa	0,1164
bancario	-0,0025					Acciones	-0,0079
finanzas	0,0085					Agua	-0,0079
riqueza	-0,0068					Alimento	-0,0275
consumir	0,0073					Alojamiento	-0,0016
Libertad	0,0015					Beneficios	-0,0187
beneficios	0,0096					Casa	-0,0028
inversión	0,0105					Cobertura	0,0087
						Cocina	-0,0179
						Compra	-0,0742
						Consumir	0,0011
						Desempleo	-0,0082


Tabla 7.5: Resultado de Coeficientes de términos no excluidos en regresión LASSO, período de crisis. Software utilizado Rstudio.

Comparando los resultados de ambos periodos, los términos que permanecen en período completo y de crisis en Chile son: “crédito”, “vender”, “precio del oro”, “precio del cobre”, “covid”, “AFP”, “sequía”, “acciones”, “bonos”, “bolsa de valores”, “riqueza”, “consumir” y “inversión”, además los coeficientes en ambos períodos obtienen signo igual negativo o positivo.

Los términos que desaparecen en incidencia en tiempos de crisis son: “impuestos”, “crisis”, “casa”, “viaje”, “cocina” y “emprendimiento”, los que términos de búsqueda que tienen incidencia en inversión como “casa” y “emprendimiento” y los de ocio como “viaje” y “cocina”, son coherentes en que desaparezcan como predictores en época de crisis. Finalmente, los términos que aparecen con significancia en el período de crisis son: “deuda”, “cáncer”, “dinero”, “riesgo”, “medio ambiente”, “guerra”, “retorno”, “crecimiento”, “cobertura”, “bancario”, “finanzas”, “libertad” y “beneficios”.


En la figura 7.2, se aprecia que los aumentos de volatilidad reflejan la caída del precio del IPSA en el periodo analizado, se ve claramente con la llegada del COVID-19 al país, es decir, gran parte de esta volatilidad afecta en forma negativa al mercado de Chile.

Figura 7.2: Evolución de Precio de IPSA y Volatilidad de IPSA. Software utilizado Rstudio.




En la figura 7.3, se aprecia los volúmenes de búsquedas y el indicador de volúmenes de búsqueda anormales de los términos seleccionados como predictores, con la regresión LASSO, donde se puede visualizar que aumenta la intensidad de búsqueda de estos términos en el periodo de la pandemia en Chile.

Figura 7.3: Evolución de Volúmenes de Búsqueda en Google desde Chile. Software utilizado Rstudio.




En la Figura 7.4, se aprecia que la volatilidad, al igual a Chile, generalmente en el periodo de arribo de la pandemia, está afecta negativamente al precio del índice en México, salvo al final del período de estudio.

Figura 7.4: Evolución de Precio de BMV IPC y Volatilidad de BMV IPC. Software utilizado Rstudio.




En la Figura 7.5, Los volúmenes de búsqueda ASVI y volúmenes de búsqueda anormales ASVA, presentan mayor intensidad cuando arriba el COVID-19 en México.

Figura 7.5: Evolución de Volúmenes de Búsqueda en Google desde México. Software utilizado Rstudio.



En la Figura 7.6, La evolución del precio del índice COLCAP, se ve afectado por irrupción de la pandemia, donde en un periodo corto, el mercado experimenta una alta volatilidad, afectando al mercado negativamente, sin embargo, anterior a este evento y posterior a él, la volatilidad en el índice de Colombia baja notoriamente y parecería o tener mucha relación con la caída o subidas de precios en este mercado.


Figura 7.6: Evolución de Precio de COLCAP y Volatilidad de COLCAP. Software utilizado Rstudio.



En la Figura 7.7, El volumen de búsqueda desde Google, de acuerdo con los términos obtenidos para Colombia (ASVI), se visualiza que aumenta la intensidad hacia el primer caso de COVID-19, posterior a esa fecha tiende a desacelerar, de igual forma que los mercados de Chile y México, la intensidad de


búsqueda de los términos seleccionados para el mercado aumenta en periodo de pandemia.

Figura 7.7: Evolución de Volúmenes de Búsqueda en Google desde Colombia. Software utilizado Rstudio.




En la Figura 7.8, La volatilidad en el índice del Perú muestra notoriamente el aumento en periodo de pandemia en el país, donde afecta los precios en las caídas posteriores al primer caso de COVID-19.

Figura 7.8: Evolución de Precio de SP Perú Select y Volatilidad de SP Perú Select. Software utilizado Rstudio.



En la Figura 7.9, El volumen de búsqueda desde Google, de acuerdo con los términos obtenidos para Perú ASVI, muestra que la intensidad de búsqueda de los términos no experimenta mayor intensidad con la llegada de la pandemia.

Figura 7.9: Evolución de Volúmenes de Búsqueda en Google desde Perú. Software utilizado Rstudio.



En la tabla 7.4, se puede visualizar que la volatilidad mensual calculada a través de los precios de los índices, la media mayor la obtiene el IPSA y el menor promedio de volatilidad mensual la obtiene el índice BMV IPC, manteniéndose ese patrón de volatilidad en frecuencia anual, con respecto al período definido como de crisis de pandemia y parte del inicio de la guerra de Ucrania y Rusia, aumenta el promedio de volatilidad en todos los índices, como se visualizó gráficamente anteriormente. Revisando los índices de volúmenes de búsquedas anormales en el motor de Google, el índice ASVA local muestra que en periodo completo el promedio mayor lo obtiene el índice IPSA y el menor (negativo) el índice SP Perú Select, en el período de crisis el promedio baja en todos los índices y en tres índices obtienen promedio negativo.

	IPSA	COLCAP	BMV IPC	SP PERU SELECT
Panel A: $\ln RV_t^M$ (Varianza Logarítmica Mensual) – Período Completo				
Media	0.023	0.020	0.018	0.021
Desv. Std.	0.017	0.022	0.010	0.014
Mediana	0.018	0.017	0.016	0.017
$\rho(1)$	0.934	0.923	0.915	0.922
$\rho(10)$	0.270	0.134	0.289	0.255
Panel A: $\ln RV_t^A$ (Varianza Logarítmica Anual) – Período Completo				
Media	0.024	0.020	0.018	0.021
Desv. Std.	0.013	0.015	0.007	0.011
Mediana	0.019	0.016	0.017	0.017

$\rho(1)$	0.985	0.982	0.982	0.984
$\rho(10)$	0.500	0.315	0.552	0.457
Panel A: $\ln RV_t^M$ (Varianza Logarítmica Mensual) – Período de Crisis				
Media	0.031	0.025	0.021	0.027
Desv. Std.	0.020	0.029	0.012	0.017
Mediana	0.029	0.019	0.019	0.021
$\rho(1)$	0.915	0.917	0.913	0.910
$\rho(10)$	0.061	0.062	0.310	0.074
Panel A: $\ln RV_t^A$ (Varianza Logarítmica Anual) – Período de Crisis				
Media	0.031	0.025	0.021	0.027
Desv. Std.	0.014	0.020	0.009	0.012
Mediana	0.030	0.019	0.019	0.022
$\rho(1)$	0.973	0.978	0.983	0.977
$\rho(10)$	0.216	0.198	0.520	0.234
Panel B: $ASVA_t^{Local}$: Intensidad Anormal de volumen de búsqueda Local – Período Completo				
Media	0.080	0.009	0.004	-0.002
Desv. Std.	0.098	0.100	0.088	0.125
Mediana	0.072	0.000	0.000	0.008
$\rho(1)$	0.444	0.538	0.234	0.502
$\rho(10)$	-0.037	-0.172	0.021	0.276
Panel B: $ASVA_t^{Local}$: Intensidad Anormal de volumen de búsqueda Local – Período de Crisis				
Media	-0.003	0.013	-0.002	-0.000
Desv. Std.	0.074	0.112	0.084	0.099
Mediana	-0.001	-0.002	-0.008	0.005
$\rho(1)$	0.430	0.517	0.396	0.483
$\rho(10)$	-0.083	0.014	-0.020	-0.016
Panel C: $ASVA_t^{Global}$: Intensidad Anormal de volumen de búsqueda Global – Período Completo				
Media	0.003	0.027	0.029	0.031
Desv. Std.	0.065	0.065	0.067	0.063
Mediana	0.003	0.028	0.024	0.023
$\rho(1)$	0.432	0.459	0.575	0.567
$\rho(10)$	0.071	0.091	0.054	-0.055

Panel C: $ASVA_t^{Global}$: Intensidad Anormal de volumen de búsqueda Global –
Período de Crisis

Media	0.003	-0.001	0.003	0.002
Desv. Std.	0.066	0.057	0.063	0.068
Mediana	0.0038	0.001	0.002	-0.003
$\rho(1)$	0.476	0.487	0.570	0.525
$\rho(10)$	0.074	-0.052	0.066	0.008

Tabla 7.6: Estadísticos Descriptivos. Software utilizado Rstudio.

ρ : es el coeficiente de autocorrelación en el orden dado.

En la tabla 7.5, se muestran las matrices de los coeficientes de volatilidad e índices de volúmenes de búsquedas en Google, donde se puede apreciar correlaciones positivas al analizar los datos del índice IPSA, visualizando que la correlación de los índices de búsqueda anormales ASVA local y Global aumentan con la respecto a la volatilidad mensual y anual en el período de crisis.

En relación con las correlaciones del índice COLCAP también son positivos con respecto a la volatilidad mensual y anual y aumenta en el periodo de crisis.

Los datos de correlación del índice BMV IPC, en el periodo de crisis, obtiene correlaciones negativas, con el índice de búsquedas anormales a nivel local con respecto a las variables de volatilidad mensual y anual. El índice de búsqueda anormal global presenta correlación positiva con incrementos en el periodo de crisis con respecto a la volatilidad mensual del índice.

El índice SP Perú Select, sigue el patrón de aumentar la correlación positiva entre la volatilidad mensual y anual con respecto al índice de búsqueda anormal local, de igual forma con la correlación entre los indicadores de volatilidad y el índice de búsqueda anormal global, pero sólo con respecto a la volatilidad anual en el periodo completo obtiene correlación negativa.

	Período Completo				Período de Crisis			
IPSA	RV_t^M	RV_t^A	$ASVA_t^L$	$ASVA_t^G$	RV_t^M	RV_t^A	$ASVA_t^L$	$ASVA_t^G$
RV_t^M	1,000				1,000			
RV_t^A	0,748	1,000			0,669	1,000		
$ASVA_t^{Local}$	0,144	0,054	1,000		0,179	0,120	1,000	
$ASVA_t^{Global}$	0,131	0,117	0,205	1,000	0,261	0,144	0,351	1,000
COLCAP	RV_t^M	RV_t^A	$ASVA_t^L$	$ASVA_t^G$	RV_t^M	RV_t^A	$ASVA_t^L$	$ASVA_t^G$
RV_t^M	1,000				1,000			

RV_t^A	0,684	1,000			0,656	1,000		
$ASVA_t^{Local}$	0,387	0,088	1,000		0,407	0,112	1,000	
$ASVA_t^{Global}$	0,141	0,139	0,173	1,000	0,097	0,101	0,372	1,000
BMV IPC	RV_t^M	RV_t^A	$ASVA_t^L$	$ASVA_t^G$	RV_t^M	RV_t^A	$ASVA_t^L$	$ASVA_t^G$
	RV_t^M	1,000			1,000			
	RV_t^A	0,766	1,000		0,746	1,000		
	$ASVA_t^{Local}$	0,061	0,040	1,000	-	-	1,000	
					0,009	0,006		
	$ASVA_t^{Global}$	0,254	0,184	0,189	1,000	0,290	0,181	0,413
SP PERU	RV_t^M	RV_t^A	$ASVA_t^L$	$ASVA_t^G$	RV_t^M	RV_t^A	$ASVA_t^L$	$ASVA_t^G$
	RV_t^M	1,000			1,000			
	RV_t^A	0,749	1,000		0,695	1,000		
	$ASVA_t^{Local}$	0,013	0,084	1,000	0,252	0,170	1,000	
	$ASVA_t^{Global}$	0,163	-0,003	0,071	1,000	0,203	0,004	0,091
								1,000

Tabla 7.7: Matriz de autocorrelación. Software utilizado Rstudio.

El resultado de los tres modelos sometidos a regresiones, son los siguientes:

los resultados de la primera ecuación se observan que los estimadores que representa la varianza mensual obtienen significancia estadística en todos los índices del MILA, no obstante, el estimador anual de volatilidad solo obtiene significancia estadística en todo el período definido de estudio es el índice COLCAP.

El coeficiente de determinación está por sobre el 83%, lo que significa que la volatilidad del mes siguiente es explicada con la volatilidad del mes anterior y el indicador anual en más del 83% en todos los índices estudiados.

El test de Durbin Watson da sospechas de autocorrelación positiva, y al revisar el test de White, rechaza la hipótesis nula en todos los índices, esto significa que la varianza no es constante y homocedástica.

Con respecto al período de crisis los estimadores de varianza mensual obtienen todos los índices, significancia estadística y la varianza anual obtienen dos índices significancia estadística, al igual que el período completo el test de Durbin Watson sugiere la existencia de autocorrelación positiva y el Test de White también indica que no existe varianza constante u homocedástica, ahora bien, bajo esta perspectiva los estimadores pueden seguir siendo insesgados, pero pierden eficiencia.

Revisando la ecuación dos, que incorpora el predictor de volumen de búsqueda local, los estimadores de volatilidad mensual y anual obtienen significancia estadística, en el Índice IPSA.

El indicador de volumen de búsqueda anormal local, en sólo tres índices obtienen significancia estadística (IPSA, COLCAP, BMV IPC) y en período de crisis obtienen significancia estadística en el índice de volumen de búsqueda anormal local los índices COLCAP, BMV IPC y SP PERU SELECT.

El estimador de volatilidad mensual obtiene significancia estadística y el estimador anual de volatilidad solo lo obtiene el índice IPSA.

Analizando test Durbin Watson sugiere la existencia de autocorrelación positiva, el problema que se puede tener es la subestimación del error estándar de los coeficientes.

Con respecto a los estimadores de volatilidad mensual y anual, los estimadores de volatilidad y el indicador mensual obtiene significancia estadística en todos los índices del MILA, y volatilidad anual únicamente obtienen significancia estadística el índice IPSA y COLCAP.

Revisando los resultados de la ecuación que agrega el predictor de búsqueda de volúmenes anormales global período completo, el estimador obtiene significancia estadística en dos índices (IPSA, BMV IPC) y en período de crisis solo México (BMV IPC) no obtiene significancia estadística.

Con respecto a la prueba de White, donde se rechaza que la serie tenga varianza constante, también en el periodo completo el estimador de la volatilidad mensual obtiene significancia estadística en todos los índices, no así en la volatilidad anual.

El coeficiente de determinación (R^2) se encuentra por sobre el 83%, lo que indica que los estimadores explican la volatilidad mensual en ese porcentaje.

En relación con el período de crisis, verificando los estimadores de volatilidad mensual y anual, mensual obtiene significancia estadística en todos los índices, sin embargo, en volatilidad anual solamente obtienen significancia estadística los índices de Chile (IPSA) y Colombia (COLCAP), y con respecto al predictor de volumen de búsqueda anormal global obtienen significancia estadística los índices IPSA, COLCAP y SP PERU SELECT.

Los estimadores de volatilidad, el indicador mensual obtiene significancia estadística en todos los índices del MILA, y volatilidad anual solo obtienen significancia estadística el índice IPSA y COLCAP.

	IPSA	COLCAP	BMV IPC	SP PERU SELECT
Panel A: Modelo de referencia – Período Completo				
Intercepto	0.0022*	0.0025*	0.0017*	0.0020*
P-Value	(0.004)	(0.003)	(0.004)	(0.006)
ln(RV_t^M) Varianza Mensual	0.9750*	0.9681*	0.9333*	0.9450*
P-Value	(0.0000)	(0.000)	(0.000)	(0.000)
ln(RV_t^A) Varianza Anual	-0.0686	-0.0919*	-0.0271	-0.0395
P-Value	(0.107)	(0.045)	(0.575)	(0.400)
R²	0.87	0.85	0.84	0.85
Durbin – Watson	0.809	0.592	1.063	0.792
White Test	20.66**	41.05**	9.81**	10.48**
P-Value	(0.000)	(0.000)	(0.000)	(0.000)
Panel A: Modelo de referencia – Período de Crisis				
Intercepto	0.0045*	0.0038*	0.0021*	0.0036*
P-Value	(0.007)	(0.019)	(0.045)	(0.012)
ln(RV_t^M) Varianza Mensual	0.9798*	0.9711*	0.9290*	0.9553*
P-Value	(0.000)	(0.000)	(0.000)	(0.000)
ln(RV_t^A) Varianza Anual	-0.1243*	-0.1160*	-0.0258	-0.0883
P-Value	(0.055)	(0.076)	(0.709)	(0.191)
R²	0.85	0.84	0.83	0.83
Durbin – Watson	0.824	0.566	1.055	0.775
White Test	8.75**	25.34**	5.09**	5.13**
P-Value	(0.000)	(0.000)	(0.000)	(0.000)
Panel B: Modelo Volumen de búsqueda anormal local – Período Completo				
Intercepto	0.0028*	0.0026*	0.0018*	0.0020*
P-Value	(0.000)	(0.002)	(0.003)	(0.008)
ln(RV_t^M) Varianza Mensual	0.9858*	0.9167*	0.9302*	0.9433*
P-Value	(0.000)	(0.000)	(0.000)	(0.000)
ln(RV_t^A) Varianza Anual	-0.0758*	-0.0531	-0.0263	-0.0362
P-Value	(0.074)	(0.253)	(0.585)	(0.444)
lnASVA_t^{Local}	-0.0085*	0.0184*	0.0047*	-0.0017
P-Value	(0.034)	(0.001)	(0.090)	(0.535)

R²	0.87	0.85	0.84	0.85
Durbin – Watson	0.835	0.618	1.085	0.793
White Test	10.87**	29.21**	11.47**	6.23**
P-Value	(0.000)	(0.000)	(0.000)	(0.000)
Panel B: Modelo Volumen de búsqueda anormal local – Período Crisis				
Intercepto	0.0046*	0.0040*	0.0021*	0.0031*
P-Value	(0.007)	(0.009)	(0.033)	(0.033)
ln(RV_t^M) Varianza Mensual	0.9790*	0.8814*	0.9297*	0.9776*
P-Value	(0.000)	(0.000)	(0.000)	(0.000)
ln(RV_t^A) Varianza Anual	-0.1243*	-0.0548	-0.0255	-0.0896
P-Value	(0.056)	(0.383)	(0.695)	(0.177)
lnASVA_t^{Local}	0.0013	0.0396*	0.0194*	-0.0150*
P-Value	(0.886)	(0.000)	(0.000)	(0.018)
R²	0.85	0.86	0.85	0.84
Durbin – Watson	0.821	0.674	1.136	0.834
White Test	5.42**	20.54**	5.11**	3.25**
P-Value	(0.0000)	(0.000)	(0.000)	(0.001)
Panel C: Modelo Volumen de búsqueda anormal Global – Período Completo				
Intercepto	0.0023*	0.0024*	0.0017*	0.0018*
P-Value	(0.002)	(0.006)	(0.003)	(0.019)
ln(RV_t^M) Varianza Mensual	0.9713*	0.9659*	0.9213*	0.9313*
P-Value	(0.000)	(0.000)	(0.000)	(0.000)
ln(RV_t^A) Varianza Anual	-0.0708*	-0.0948*	-0.0257	-0.0262
P-Value	(0.095)	(0.039)	(0.594)	(0.583)
lnASVA_t^{Global}	0.0104*	0.0087	0.0064*	0.0082
P-Value	(0.080)	(0.280)	(0.091)	(0.145)
R²	0.87	0.85	0.84	0.85
Durbin – Watson	0.818	0.592	1.045	0.799
White Test	11.34**	23.90**	5.83**	6.19**
P-Value	(0.000)	(0.000)	(0.000)	(0.000)
Panel C: Modelo Volumen de búsqueda anormal Global – Período Crisis				
Intercepto	0.0051*	0.0041*	0.0021*	0.0036*
P-Value	(0.002)	(0.009)	(0.043)	(0.009)
ln(RV_t^M) Varianza Mensual	0.9486*	0.9668*	0.9245*	0.9078*
P-Value	(0.000)	(0.0000)	(0.000)	(0.000)

$\ln(RV_t^A)$ Varianza Anual	-0.1156*	-0.1233*	-0.0244	-0.0432
P-Value	(0.066)	(0.055)	(0.725)	(0.513)
$\ln ASVA_t^{Global}$	0.0326*	0.0416*	0.0023	0.0310*
P-Value	(0.002)	(0.016)	(0.736)	(0.000)
R^2	0.86	0.85	0.83	0.84
Durbin – Watson	0.832	0.560	1.045	0.814
White Test	4.54**	18.50**	3.28**	4.07**
P-Value	(0.000)	(0.000)	(0.001)	(0.000)

Tabla 7.8: Resultado de regresiones. Software utilizado Rstudio.

* Estimador con significancia estadística al 1%, 5% y 10%

** Test con significancia estadística al 1%, 5% y 10%

7.6.-Conclusión del capítulo

En el periodo analizado de cinco años, se han considerado dos periodos, uno más estable que va desde 2017 a 2019, y un período de crisis tanto pandémica y de guerra.

En la selección de búsqueda de términos focalizados en los países en estudio por medio de la extracción de datos desde la plataforma que nos ofrece Google (Google Trends GT), se realiza con frecuencia semanal, debido a que sólo se cuenta con un período de tres meses de datos diarios, esto se puede ver como una limitación a las investigaciones, ya que para estudiar cinco años que es el máximo de datos que contiene GT, se deben realizar los estudios con frecuencia semanal, sin embargo, es una valiosa información para buscar el interés y el sentir de las personas acerca de un determinado tema que se puede extrapolar como un sentir de todos frente a una situación en particular, debido a la relevancia que tiene el motor de búsqueda principalmente en occidente. Un estudio realizado en cinco mercados emergentes de Asia encontró que el modelo de valoración de Fama y French no siempre es efectivo y las búsquedas en el motor de Google acerca de los mercados, influye en el rendimiento de las acciones de los mercados, indicando que los inversionistas de estos mercados son más sensibles a las malas noticias que a las buenas noticias. (Nguyen, Schinckus, & Nguyen, 2019)

Los hallazgos obtenidos son: al comienzo de la pandemia de COVID-19 en los países estudiados, perdieron rápidamente el valor de los índices, en poco tiempo, en ese periodo se observa que los indicadores de sentimiento a través del volumen de búsqueda local de Google se intensifican el volumen de los términos

seleccionados como predictores, y resultan con significancia estadística sobre la volatilidad mensual en los índices IPISA, COLCAP, BMV IPC, lo que indica que en estos índices, las variables, a partir de vocablos de consulta en Google, capturan el sentir de los inversionistas en el período completo de estudio desde 2017 hasta 2022.

Revisando el periodo de crisis delimitado desde octubre de 2019 a abril de 2022, que involucra la irrupción de la pandemia y llegada del COVID a los países que conforman el MILA, e inicio de la guerra de Ucrania y Rusia, donde los predictores seleccionados a partir de datos que provee Google, e índices bursátiles, COLCAP, BMV IPC y SP PERU SELECT, obtienen significancia estadística, con coeficiente de determinación R^2 , mayor al 84%, donde indica que tanto el estimador de rentabilidad mensual, anual y volumen de búsqueda a nivel geográfico local, explican la volatilidad mensual en más del 84%.

Revisando los estimadores de volúmenes de búsquedas anormales locales en el período de crisis, tres índices COLCAP, BMV IPC y SP PERU SELECT, obtienen significancia estadística, con coeficiente de determinación mayor igual a 84%. En periodo de crisis, los estimadores de volumen de búsquedas anormales global, obtiene significancia estadística, los datos correspondientes a los índices IPISA, COLCAP y SP PERU SELECT.

Como conclusión final se aprecia claramente en tres mercados Chile, Colombia y México una mayor intensidad de volúmenes de búsquedas en el período de crisis, poseen un poder predictivo que varía en cada país, ahora bien donde se deja próximos pasos que mejoren este estudio es en la elección de términos de búsquedas, que sean más apropiados por país, en ese caso sería útil formar una base de conocimiento más amplia que la utilizada en la presente investigación, además del uso de herramientas, tecnológicas a partir del Big Data, se puede construir un sistema o algoritmo que pueda probar un gran número de términos, y someterlos a regresiones de elección de predictores, como el utilizado en este trabajo (Ver Anexo B).

Como se citó en la revisión de la literatura existen amplios estudios que ha llegado a la conclusión de que los datos provistos por el motor de búsqueda y también de redes sociales, como lo es un estudio que utilizó solo dos términos ("mercado financiero" y "mercado de valores") con mensajes cortos de Twitter ayudan a mejorar significativamente el pronóstico de la volatilidad ([Audrino, Sigrist y Ballinari 2020](#)).

La originalidad de la investigación es aplicarla en mercados en desarrollo latinos, no existen muchos estudios acerca del tema y se perfila como el futuro para ir sustituyendo el supuesto de aversión al riesgo de los agentes del mercado, donde se erige como una forma de incorporar el estudio de las finanzas conductuales, tanto al análisis técnico, y la metodología de modelos matemáticos, donde la obtención de los datos no tiene costo, ni tampoco se requiere de encuestas que hacen más engorroso, el proceso de obtener predicciones en cada momento.

Otro aspecto que se encuentra en el estudio es que el volumen de búsqueda de los términos seleccionados por medio de la regresión LASSO, experimentan incremento en intensidad en tres países del MILA (Chile, Colombia y México), donde sugieren que en época de crisis la atención de los inversores se incrementa en el buscador, en relación con la volatilidad en los mercados, en este sentido es coincidente con estudios anteriores ([Hamid y Heiden 2015](#)).

El estudio encuentra que la turbulencia causada por la llegada del COVID-19 a los países, evidencia un incremento en la intensidad de búsqueda de los términos obtenidos como predictores a través del proceso de la regresión LASSO, existe un aumento en la correlación con las volatilidades, como consecuencia a este aumento de sentimiento de miedo por la pandemia en el corto plazo, tiene incidencia en el rendimiento de los índices de los países del MILA, mostrando en la mayoría de los casos, poder predictivo en una medida baja aún, pero con significancia estadística, lo que deja a futuras investigaciones la idea de generar una base de conocimientos de términos que sean más apropiados para un mercado en particular, de acuerdo con sucesos o hechos locales y globales que puedan afectar a los países, en tiempos de temor, y que este sentir se puedan extrapolar hacia el mercado de valores.

Capítulo 8 : Conclusiones

8.1.- Introducción

El proceso para responder la interrogantes que se plantea este trabajo de investigación acerca de cómo afectó la pandemia del COVID-19, al mercado bursátil chileno, como punto de partida para extrapolar esta investigación a los índices que componen el MILA (Mercado Integrado Latinoamericano). Bajo un precepto de ir buscando factores de riesgo que permiten incluir al modelo de valoración variables exógenas que den cuenta del comportamiento de los agentes que participan en el mercado, proveniente de volatilidad de los mercados, intensidad de búsquedas en internet por medio de motores de búsquedas, del miedo de mercados más volátiles como lo son las criptomonedas, además de los datos que provienen de la pandemia como son los nuevos casos confirmados a nivel mundial o local, y la cantidad de muertes a causa del COVID-19.

Para seguir este desarrollo las preguntas planteadas en la investigación fueron las siguientes:

¿ Antes de la pandemia del COVID-19, el estado de mercado de valores chilenos se encuentra en la forma de eficiencia débil de Fama y French ?.

¿ Es adecuado que el modelo CAPM de un factor, se continúe aplicando en la valoración de los activos en este mercado ?,

Estas dos interrogantes contribuyen al objetivo de investigación en relación con determinar el estado en términos de forma de eficiencia del mercado y validez de utilizar el modelo de valoración CAPM de un factor.

El segundo paso de este proceso lleva a examinar el mercado bursátil a partir de la aplicación de un estudio de eventos, para responder la siguiente interrogante:

¿ El mercado chileno actuó de manera eficiente ante la llegada del COVID-19 ?

Con esta etapa de la investigación sirve para despejar la duda, si este mercado necesita de un modelo de valoración que pueda aportar información sobre el comportamiento de las personas que toman decisiones de compra o venta de activos.

Posteriormente en este mercado se evalúan cuatro modelos de valoración más tradicionales derivados del modelo CAPM, en período con y sin pandemia del COVID-19, busca responder la interrogante planteada acerca de : ¿ Qué modelo

de valoración clásico es de mejor rendimiento en el mercado de valores de Chile, en periodo sin pandemia y con pandemia del COVID-19 ?. De este proceso se obtiene el modelo de mejor rendimiento en el mercado chileno, el cual se convierte en el modelo candidato para agregar factores de riesgo exógenos que aporten información relativa al comportamiento de los agentes en el mercado.

Como último proceso se someten a análisis de causalidad tres tipos de factores de riesgo exógenos candidatos, aplicados a los índices de Chile, Colombia, México y Perú. Respondiendo al pregunta planteada de ¿Cuál o cuáles factores exógenos al modelo de valoración, poseen información relevante, en situación de pandemia?

Para establecer una línea de investigación futura es relevante contribuir a iniciativas recientes que es llevar estos modelos de valoración hacia herramientas de inteligencia artificial, que permitan superar supuestos de comportamiento de los agentes del mercado, como también se construyen bases de datos disponibles para realizar valoraciones en tiempo real de los activos y pronósticos en tiempo real de los activos en mercados emergentes, con la ayuda de captar el optimismo o temor de las personas que participan en los mercados, en esta línea se planteó la siguiente interrogante: La intensidad de búsquedas de términos asociados al temor en un momento determinado, tiene relación con las acciones que toman los agentes en el mercado en estudio, en la crisis sanitaria?

8.2.- Conclusiones.

A continuación, se resumen las conclusiones de la tesis:

PRIMERA: Se comprueba la eficiencia débil del mercado en Chile en el periodo antes de pandemia, es decir, los precios reflejan toda la información pasada, lo que implica que en el tiempo examinado los inversores no pueden obtener rentabilidades superiores analizando estas series de precios de los activos, o extrapolando reglas de comportamiento en los precios de las acciones, por lo tanto, se descarta la asimetría de información en el periodo analizado. Cuando los precios se comportan en forma aleatoria, el análisis técnico, que estudia los precios y sus tendencias para predecir el precio futuro, el que se apoya en el análisis gráfico denominado como “Chartistas”, no sirve su aplicación, por consiguiente, los resultados que obtengan los analistas que utilizan este instrumento van a ser producto del azar, no así el análisis fundamental que estudia las causas del comportamiento de los mercados, utilizando modelos de valoración de activos. (Czupryna, Kubińska, & Markiewicz, 2015).

Investigaciones que han comprobado la forma de eficiencia débil en los índices que componen el MILA, en distintos periodos de tiempo, antes de la pandemia del COVID-19. (Ruiz Dávila & García Muñoz, 2020), (Ramírez, Valencia, & Villalba, 2017), (Meneses Cerón & Pérez Pacheco, 2020). Obteniendo los mismos resultados que esta tesis, en la comprobación del estado de forma de eficiencia débil del mercado antes de la pandemia.

SEGUNDA: De acuerdo a el análisis de carteras ordenadas por el nivel de riesgo del Índice IPSA, se concluye que la intercepción de riesgo retorno no es cero y presenta pendiente negativa, por lo que no cumple la relación de riesgo retorno que indica que a mayor riesgo mayor retorno. Además, el activo libre de riesgo utilizado en el estudio que es el bono emitido por la República de Chile a un año no es el adecuado para el modelo, y finalmente el factor de riesgo tiene una baja explicación en el modelo y tiempo de estudio en los activos del IPSA, indicando que faltan factores de riesgo en este mercado. Las investigaciones de (Fama, Eugene; French, Kenneth, 1996) (Fama & French, 2015) (Carhart, 1997), proponen la modificación del modelo CAPM de un factor, de acuerdo a estudios aplicados a un mercado de gran desarrollo como Estados Unidos, utilizando la misma metodología replicada en esta tesis, para el mercado chileno.

TERCERA: En el período estudiado se obtiene como hallazgo que el modelo CAPM de un factor no tiene validez en el mercado chileno, esto indica que estamos en ausencia de factores de riesgo del mercado, que poseen información relevante de los activos. Esto es importante debido a la amplia utilización de este modelo por analistas financieros debido a su simplicidad de aplicación. Por lo tanto, una condición necesaria antes de aplicar un modelo de valoración en un tiempo determinado es la de revisar la validez de los factores de riesgo que utiliza.

CUARTA: En el análisis de la eficiencia financiera en el mercado en Chile, con la llegada de la pandemia. Se obtiene como hallazgo que posterior al evento de primer caso de COVID-19 (3 de marzo de 2020) en Chile, todos los sectores industriales, obtienen retornos anormales negativos, excepto el sector de servicios públicos (Utilities). Los retornos anormales tienen impacto disímil de acuerdo a las industrias al igual que un estudio realizado en China, donde encuentra como descubrimiento retornos anormales significativamente negativos después del brote del COVID-19 en las industria de energía y finanzas (Wang & Yu, 2022). Asimismo, en otras economías del mundo también se obtiene como hallazgo el mismo comportamiento del mercado. (Wajid & Gupta, 2022)

(Herwany, Febrian, Anwar, & Gunardi, 2021). Que el mercado no haya incorporado la información de la pandemia y no corrija a la baja los retornos y éstos continúen bajando abruptamente, indica que el mercado no logro mantener la eficiencia en su forma débil establecido en el período sin pandemia. Los sectores industriales que obtienen retornos acumulados negativos menores al 10%, son el bancario y consumo, estos sectores permiten una opción de diversificación, para una alternativa de mitigación frente a mayores pérdidas en tiempos de crisis sanitaria.

QUINTA: En el período de crisis sanitaria, el mercado de valores de Chile no actúa eficiente en ninguna de las formas de eficiencia establecidas por Fama French. Esta ineficiencia implica que no incorpora la información acerca de la pandemia y experimenta una reacción exagerada posterior al evento en todas las industrias del mercado chileno. No sólo los mercados emergentes actuaron con ineficiencia frente a la pandemia una investigación realiza en Estados Unidos, encuentra fuerte pérdida de eficiencia en ese mercado bursátil con la irrupción del COVID-19 (Ammy-Driss & Garcin, 2023) (Navratil, Taylor, & Vecer, 2021).

SEXTA: Cuando ocurre la sobre-reacción del mercado chileno frente al COVID-19, existen dos sectores industriales (no financieros) donde la reacción es menor a la crisis de la pandemia, estos son el sector de consumo y de servicios públicos (Utilities). Investigaciones por sector, encuentran que algunos sectores como lo son consumo, servicios médicos y sanitarios, se ven menos afectados por la pandemia de COVID-19, debido a sectores industriales que están relacionados con la provisión de bienes y servicios que no se pueden sustituir en pandemia. (Dong, Li, Zhuang, & Wang, 2022). Estos sectores ofrecen opciones de cobertura para los portafolios de inversión.

SÉPTIMA: Posterior al evento de primer caso de pandemia, el único sector industrial que no presenta retornos anormales acumulados negativos es el de servicios públicos, por lo que ofrece un refugio de las inversiones en tiempo de pandemia, información útil para ser considerada por los analistas del mercado, en este tipo de crisis.

OCTAVA: De acuerdo con periodo de contingencia del COVID-19 y el estudio del IPSA por industria, se obtiene información relevante para los estudios de inversiones en tiempo de pandemia, donde es posible adoptar una estrategia de inversión de largo plazo, excepto en el sector de servicios públicos, donde se recomienda comprar acciones y obtener beneficios extraordinarios una vez

superada la emergencia sanitaria o corregidas las rentabilidades anormales del mercado. Esta acción se puede realizar sólo cuando un mercado se comporta ineficiente ante este tipo de crisis, como también lo ha demostrado (Jan, Li, & Xiyu, 2022) en su investigación. Estudio que encuentran impactos positivos en industrias pre y post Covid-19 en China, indican la importancia para tener en cuenta en la estrategia de inversiones futuras, frente a una crisis sanitaria.

NOVENA: En la revisión de los modelos derivados del CAPM, se obtiene que el mejor factor de riesgo, tanto en período sin pandemia y con crisis sanitaria, es el factor de tamaño bursátil SMB (Small minus Big), donde se consigue que en el mercado las empresas de menor tamaño obtienen mayores retornos que las empresas más grandes, al igual a la propuesta original de Fama French (Fama & French, 2015). En segundo lugar, el factor de mejor desempeño es el factor de premio por riesgo (RM-RF).

DÉCIMA: Los factores de riesgo que obtienen menos significancia estadística en el mercado chileno son los de rentabilidad operacional (RMW) y de inversión (CMA), resulta útil esta información para que sea tomada en cuenta por los analistas financieros en este mercado, en relación a la utilización de modelos de factores multifactoriales.

UNDÉCIMA: En periodos con pandemia y sin crisis del COVID-19, en el mercado de Chile, el modelo de Fama Cahart de cuatro factores es el de mejor desempeño, donde tienen relevancia en el mercado los factores de premio por riesgo (RM-RF), tamaño (SMB), valor (HML) y momemntum (WML), estos factores presentan más información de este mercado, en el periodo de estudio. Si bien es cierto los factores de riesgo por si solos no son suficientes para validar un modelo, se aplicó el estadístico creado por (Gibbons, Ross, & Shanken, 1989) que evalúa al modelo de valoración en su conjunto, bajo este análisis el estudio de (Kostin, Runge, & Mamedova, 2023), que revisa la validez de los modelos de valoración, con este estadístico específicamente los modelos derivados del CAPM de Fama y French de tres y cinco factores, utilizando empresas de energía que se pertenecen a los mercados bursátiles de: Rusia, China, Estados Unidos y Arabia Saudita, encuentran que los modelos de tres y cinco factores están limitados en el entorno subyacente, ya que no proporcionan resultados fiables en un entorno específico de la empresa que se ha visto afectado por crisis importantes como la pandemia de COVID-19. Donde establece como conclusión que los modelos sometidos a validez en empresas de energía no pueden capturar variables relacionadas con comportamiento irracional del mercado, ambos

modelos son profundamente arraigado en la teoría financiera tradicional, descuidando así la influencia del comportamiento humano sobre decisiones de inversión. Puede haber una mayor variedad de factores influyentes que los puramente económicos, como los sesgos psicológicos, que pueden afectar el comportamiento del mercado durante situaciones de crisis. Cabe señalar que el modelo de Fama French de cinco factores también obtiene buen rendimiento, pero solo en el período sin crisis sanitaria. Adicionalmente al resultado obtenido (Mukoyi & Ogujiuba, 2022) realizaron un estudio en Sudáfrica, y obtienen como hallazgo que el modelo de Fama Cahart es de mejor desempeño en ese mercado en período con o sin pandemia.

DUODÉCIMA: En la evaluación de factores de riesgo exógenos, se utilizaron los siguientes: denominados del miedo (volatilidad), comportamiento (Twitter), y datos desde la pandemia (nuevos casos confirmados, y muertes a causa del COVID-19), se obtienen el siguiente hallazgos: los índices de volatilidad (VIX, V2X) y del miedo en el mercado de criptomonedas (FG), tienen causalidad en todos los índices del mercado MILA, esto sugiere que poseen información relevante acerca de los mercados, por lo tanto, califican como variables de riesgo. Concluyendo que se pueden incorporar a un modelo de valoración, en período de crisis sanitaria. La importancia de incorporar factores exógenos al mercado como los índices de volatilidad, para aportar a mejorar problemas de asimetría de información, ha sido objeto de estudios en otros mercados emergentes (Ruan, 2018) y en mercados desarrollados (Durand, Lim, & Zumwalt, 2011), como también el factor exógeno del miedo y la codicia (Li & Wang, 2013).

DECIMOTERCERA: En concordancia, con la búsqueda de factores de riesgo exógenos, los resultados que se obtienen acerca del indicador de sentimiento o comportamiento extrapolado a partir de la red social Twitter presentan causalidad con significancia estadística, en los índices bursátiles de Chile, Colombia y Perú, en el período de crisis del COVID-19. Por consiguiente, es un factor de riesgo relevante en estos mercados latinos. Esto indica que es un factor candidato para ser incorporado a los modelos de valoración en pandemia. Estudios en otros mercados encuentran que impactan en mayor proporción en los rendimientos del mercado las noticias negativas (Mendoza-Urdiales, Núñez-Mora, & Santillán-Salgado, 2022) (Silva de Souza & Silva Martins, 2022)

DECIMOCUARTA: El factor de riesgo construido a partir de los nuevos casos confirmados de COVID-19 a nivel mundial, tiene causalidad y significancia estadística, en los índices bursátiles de Chile, Colombia y México. El indicador

construido a partir del número de muertes a causa del COVID-19, tiene causalidad y significancia estadística solo con el índice bursátil de México. Se ha verificado el efecto de casos de COVID-19, en el mercado de Estados Unidos por (Mishra, Sharma, Karedla, & Patel, 2022). Como también en otros mercados desarrollados del grupo del G7, encontrando una relación más bien en el largo plazo por las investigaciones de (Rahman, Guotai, Gupta, Hossain, & Abedin, 2021). Otro estudio en mercados latinoamericanos encuentra que la información de casos del COVID-19, tiene relación con los movimientos de los mercados en tiempo de pandemia. (Coronado, Martinez, Gualajara, & Rojas, 2022)

DECIMOQUINTA: Los factores de riesgo que permiten crear una ligazón entre un modelo de valoración clásico y las conductas de los inversionistas, estudiado por las finanzas conductuales, se puede concluir que los índices VIX, V2X, SP&500 Twitter Sentiment, y Fear and Greed y el índice creado a partir de los nuevos casos de COVID-19 a nivel mundial, presentan información relevante en estos mercados y pueden ser utilizados como factores de riesgo en los modelos de valoración. Estudios realizados por (Ali, 2018) (Smith & O'Hare, 2022). han encontrado evidencia de que el sentimiento de los inversionistas contenidos en mensajes de Twitter contiene información útil para el proceso de valoración de activos, indicando la necesidad de incorporarlas a un modelo de valoración

DECIMOSEXTA: El modelo propuesto en esta investigación es el denominado: Fama Cahart Extendido (FCE), el modelo que mejor se ajusta es el modelo Fama Cahart de cuatro factores con extensión de noticias de redes sociales, factor de miedo de las criptomonedas, de nuevos casos de COVID-19 a nivel mundial y de volatilidad. En los mercados de Chile, México y Perú, los estimadores de sentimiento SP500 Twitter Sentiment y de volatilidad de la Eurozona V2X, son relevantes y estadísticamente significativos, por lo que se demuestra que estos estimadores, son importantes para ser considerados en las estimaciones de los índices bursátiles de Chile, México y Perú.

DECIMOSÉPTIMA: Con la irrupción del Big Data y Machine Learning, da espacio a buscar un algoritmo que permite capturar el sentir de los inversionistas. Con el objetivo de mejorar el desempeño de los modelos de valoración, actualmente con la opción de contar con datos de la plataforma que provee Google. Se obtiene como hallazgo que en tres mercados: Chile, Colombia y México, una mayor intensidad de volúmenes de búsquedas en internet en el período de crisis sanitaria, tiene un poder predictivo que varía en cada país, por lo que indica que tienen información relevante acerca del comportamiento de los

agentes en estos mercados. Estudio que encuentra que la utilización de herramientas de Machine Learning, con un mayor número de datos que puede procesar, adicionando variables macroeconómicas en este caso en un mercado desarrollado, mejora el rendimiento del modelo de valoración (Ndikum, 2020). Estudio en el mercado bursátil de India, entre 2012 y 2017, examina el índice de atención de búsquedas con datos desde Google Trends, encontrando que esta información es relevante para valorar el mercado. (Dharani, Hassan, Abedin, & Ismail, 2022), como también en mercados desarrollados se ha encontrado la relación de intensidad de búsquedas, captura la atención de los inversionistas. (Costola, Iacopini, & Santagiustina, 2021)

DECIMOCTAVA: Al final de este trabajo de investigación explora la posibilidad de realizar un sistema informático, que pueda realizar todo el proceso descrito en el capítulo, además de ser de bajo costo (software opensource y datos de acceso público), es posible procesar una base de conocimiento más amplia en la búsqueda de más y/o mejores predictores. Los algoritmos que se utilizaron en este estudio se pueden ver en el Anexo B.

8.3.- investigaciones futuras.

Para futuras investigaciones se propone además de generar una base de conocimiento de términos de búsqueda para cada mercado en particular, también es desafiante ir incorporando variables que provengan del cambio climático en estos mercados, que puedan servir como fuente de riesgos para el tiempo que estamos viviendo y que viene, donde existen diversos impactos en zonas geográficas del mundo y estos problemas puedan afectar al desempeño de los activos financieros.

Los sistemas de inteligencia artificial (IA), basados en varias herramientas como algoritmos de machine learning, datos disponibles en la nube procesados con algoritmos y lenguajes informáticos que provienen del Big Data, pueden tener cierta autonomía y aprendizaje continuo para hacer predicciones, recomendaciones o decisiones utilizando un número masivo de alternativas y datos.


La crisis del COVID-19 ha acelerado e intensificado la tendencia de digitalización que ya se observaba antes de la pandemia, incluso en torno al uso de la IA. La creciente adopción de IA en finanzas, en áreas como la gestión de activos, el comercio algorítmico, la suscripción de créditos y los servicios financieros

basados en blockchain, es posibilitada por la abundancia de datos disponibles y por una mayor y más asequible capacidad informática. (OECD, 2021).

Cuando el brote de COVID-19 se convirtió en una pandemia mundial, la volatilidad de los mercados financieros alcanzó su nivel más alto en más de una década, en medio de una incertidumbre generalizada sobre el impacto económico a largo plazo. La calma ha regresado a los mercados en los últimos meses, pero la volatilidad continúa tendiendo por encima de su promedio a largo plazo. En medio de la incertidumbre persistente, las instituciones financieras buscan desarrollar capacidades cuantitativas más avanzadas para respaldar una toma de decisiones más rápida y precisa. En un entorno impredecible, se requería que los modeladores financieros encontraran soluciones. Dada la velocidad de respuesta requerida, los modelos en algunos casos quedaron inutilizables. El resultado inevitable fue un aumento en las exposiciones al riesgo y la opacidad de las valoraciones, a veces en valor absoluto y otras veces en relación con la razón de los resultados específicos del modelo. En respuesta algunas instituciones líderes han comenzado a machine learning a modelos de valoración tradicionales, por ejemplo, en la calibración de parámetros en forma más eficiente, logrando con estas herramientas lo siguiente: Acelerar los cálculos, reducir tiempo operativos, permitir la gestión de riesgos en tiempo real, ayudando a compensar el impacto disruptivo de los movimientos del mercados relacionados con el COVID-19. (Baquero, Gyarmati, Silva, Laurent, & Wegner, 2020).

En la esa misma línea de investigación se verifica el aumento de estudios realizados a partir de la irrupción de la pandemia. Podemos apreciar la figura 8.1, el aumento de publicaciones de Machine Learning para valorar activos. (Zapata & Mukhopadhyay, 2022)

Figura 8.1: Número de artículos publicados de Machine Learning en Asset Pricing, Web of Science: Fuente: (Zapata & Mukhopadhyay, 2022)



De acuerdo al avance tecnológico de lo que ha se denominado la revolución de los datos, los supuestos para simplificar la realidad y poder generar modelos, que sean prácticos en su aplicación, en el área de las finanzas corporativas surgieron a partir del término de la década del cincuenta, si bien tuvieron la limitante de la disponibilidad de herramientas que procesen muchos datos y que estos datos también en muchas áreas geográficas estuvieran disponibles, han sido relevantes a la hora de valorar activos, no obstante hoy en día con el surgimiento de herramientas de machine learning, big data y que los datos estén ampliamente disponibles a través de internet. Esta posibilidad de disposición de datos y herramientas tecnológicas abre la posibilidad de investigar en solucionar algunos problemas ampliamente documentados de los modelo de valoración de activos, integrando la econometría financiera, modelos de valoración y herramienta del Big data y machine learning.

Bibliografía

- Abd-Alla, M., & Sobh, M. (2020). Empirical Test of Fama and French Three-Factor Model in the Egyptian Stock Exchange. *Financial Assets and Investing*. Vol. 11, 5-18.
- Abinzano, I., Muga, L., & Santamaria, R. (2010). The role of over-reaction and the disposition effect in explaining momentum in Latin American emerging markets. *investigación económica*, vol. LXIX, 273, 151-186.
- Abuzayed, B., Bouri, E., Al-Fayoumi, N., & Jalkh, N. (2021). Systemic risk spillover across global and country stock markets during the COVID-19 pandemic. *Economic Analysis and Policy*, 71, 180–197.
- Adekoya, O. B., & Oliyide, J. A. (2022). Commodity and financial markets' fear before and during COVID-19 pandemic: Persistence and causality analyses. *Resources Policy* Vol 76, 1-7.
- Adnan, A. T., Hasan, M. M., & Ahmed, E. (2020). Capital Market Reactions to the Arrival of COVID-19: A Developing Market Perspective. *The Economic Research Guardian*, Vol 10, 97-121.
- Agarwal, S., Kumar, S., & Goel, U. (2021). Social Media and the Stock Markets: An Emerging Market Perspective. *Journal of Business Economics and Management*, Vol. 22 Issue 6, 1614–1632.
- Aggarwal, R., Inclan, C., & Leal, R. (1999). Volatility in Emerging Stock Markets. *The Journal of Financial and Quantitative Analysis*, Vol. 34, No. 1, 33-55.
- Agosin, M. R., & Huaita, F. (2012). Overreaction in capital flows to emerging markets: Booms and sudden stops. *Journal of International Money and Finance* 31, 1140-1155.
- Aharoni, G., Grundy, B., & Zeng, Q. (2012). Stock Returns and the Miller-Modigliani Valuation Formula: Revisiting the Fama French Analysis. *Journal of Financial Economics*.
- Ahmed, F. (2021). Assessment of Capital Market Efficiency in COVID-19. *European Journal of Business and Management Research*, Vol 6, 42-46.

- Ahmed, F., Hina, S., Asif, R., & Muzammil, M. (2017). Financial Market Prediction using Google Trends. *International Journal of Advanced Computer Science and Applications Vol. 8, No.7*, 388-391.
- Akarsu, S., & Suer, O. (2021). How investor attention affects stock returns? Some international evidence. *Borsa Istanbul Review*, 1-11.
- Alber, N. (2020). The Effect of Coronavirus Spread on Stock Markets: The Case of the Worst 6 Countries. Available at SSRN: <https://ssrn.com/abstract=3578080>, 1-11.
- Albulescu, C. T. (2021). COVID-19 and the United States financial markets' volatility. *Finance Research Letters*, Vol. 38, 1-5.
- Algamdi, A., Mokhtar Brika, S. K., Musa, A., & Chergui, K. (2021). COVID-19 Deaths Cases Impact on Oil Prices: Probable Scenarios on Saudi Arabia Economy. *Health Economics a section of the journal Frontiers in Public Health*, Vol 9, 1-10.
- Ali, H. (2018). Twitter, Investor Sentiment and Capital Markets: What Do We Know? *International Journal of Economics and Finance*; Vol. 10, No. 8, 1-14.
- Allais, M. (1953). Le Comportement de l'Homme Rationnel devant le Risque: Critique des Postulats et Axiomes de l'Ecole Americaine. *Econometrica*, Vol. 21, No. 4, 503-546.
- Al-Mwalla, M., & Karasneh, M. (2011). Fama & French Three Factor Model: Evidence from Emerging Market. *European Journal of Economics, Finance and Administrative Sciences*. Vol 41., 132-140.
- Alrabadi, D. W., & Alrabadi, H. W. (2018). The Fama and French Five Factor Model: Evidence from an Emerging Market. *Arab Journal of Administration*, Vol. 38, No. 3, 295-304.
- Ammy-Driss, A., & Garcin, M. (2023). Efficiency of the financial markets during the COVID-19 crisis: time-varying parameters of fractional stable dynamics. *Physica A* 609, 1-17.
- Aouadi, A., Arouri, M., & Teulon, F. (2013). Investor attention and stock market activity: Evidence from France. *Economic Modelling Volume 35*, 674-681.

- Apergis, N., & Rehman, M. (2018). Is CAPM a Behavioral Model? Estimating Sentiments from Rationalism. *Journal of Behavioral Finance*, 1-8.
- Arisoy, Y. E., Altay-Salih, A., & Akdeniz, L. (2015). Aggregate volatility expectations and threshold CAPM. *North American Journal of Economics and Finance*, 231–253.
- Arisoya, Y. E., Altay-Salih, A., & Akdeniz, L. (2015). Aggregate volatility expectations and threshold CAPM. *North American Journal of Economics and Finance*, 231–253.
- Armeanu, D. S., Gherghina, C. S., Andrei, J. V., & Joldes, C. C. (2022). Modeling the impact of the COVID-19 outbreak on environment, health sector and energy market. *Sustainable Development Vol 1*, 2-30.
- Audrino, F., Sigrist, F., & Ballinari, D. (2020). The impact of sentiment and attention measures on stock market volatility. *International Journal of Forecasting Volume 36, Issue 2*, 334-357.
- Azam, M. (2022). The CAPM Revisited Using Structural Equation Model: Mediating Role of GDP in Pakistan Stock. *Journal of Managerial Sciences, Vol 16, , 93-108*.
- Azar, P., & Andrew W., L. (2016). The Wisdom of Twitter Crowds: Predicting Stock Market Reactions To FOMC Meetings Via Twitter Feeds. *Journal of Portfolio Management 42*, 123134.
- Bai, Y., & Green, C. J. (2020). Country and Industry Factors in Tests of Capital Asset Pricing Models for Partially Integrated Emerging Markets. *Economic Modelling, Vol 92 , 180-194*.
- Bal, D., & Mohanty, S. (2021). Sectoral Nonlinear Causality Between Stock Market Volatility and the COVID-19 Pandemic: Evidence From India. *Asian Economics Letters, Vol 2, 1-4*.
- Bali, T., & Cakici, N. (2004). Value at Risk and Expected Stock Returns. *Financial Analysts Journal, Vol. 60, Nro. 2., 57-73*.
- Baquero, J., Gyarmati, A., Silva, P. J., Laurent, M.-P., & Wegner, T. (29 de 10 de 2020). <https://www.mckinsey.com/>. Obtenido de <https://www.mckinsey.com/>: <https://www.mckinsey.com/capabilities/risk-and-resilience/our->

insights/applying-machine-learning-in-capital-markets-pricing-valuation-adjustments-and-market-risk

- Bekaert, G., & Hoerova, M. (2014). The VIX, the Variance Premium and Stock Market Volatility. *Working Paper Series, Nro. 1675*, 1-34.
- Benali, M., Lahboub, K., & El Bouhadi, A. (2023). Pricing Ability of Carhart Four-Factor and Fama–French Three-Factor Models: Empirical Evidence from Morocco. *International Journal of Financial Studies 11: 20.*, 1-14.
- Bhattacharya, U., Daouk, H., Jorgenson, B., & Kehr, C.-H. (2000). When an event is not an event: the curious case of an emerging market. *Journal of Financial Economics 55*, 69}101.
- Bijl, L., Kringhaug, G., Molnár, P., & Sandvik, E. (2016). Google searches and stock returns. *forthcoming in International Review of Financial Analysis*, 1-17.
- Bin, F.-S., Blenman, L. P., & Chen, D.-H. (2004). Valuation impact of currency crises: Evidence from the ADR market. *International Review of Financial Analysis 13*, 411 – 432.
- Binder, J. j. (1998). The Event Study Methodology Since 1969. *Review of Quantitative Finance and Accounting, Vol. 11*, 111–137.
- Black, F., Jensen, M. C., & Scholes, M. (1972). *The Capital Asset Pricing Model: Some Empirical Tests*. EEUU: Michael C. Jensen, ed., Praeger Publishers Inc.
- Bortoluzzo, A. B., Venezuela, M. K., Bortoluzzo, M. M., & Nakamura, W. T. (2016). The influence of the 2008 financial crisis on the predictiveness of risky asset pricing models in Brazil. *R. Cont. Fin. – USP, São Paulo, v. 27, n. 72*, 408-420,.
- Bouri, E., Cepni, O., Gabauer, D., & Gupta, R. (2020). Return connectedness across asset classes around the COVID-19 outbreak. *International Review of Financial Analysis, Vol. 73*, 1-11.
- Bouri, E., Demirer, R., Gupta, R., & Nel, J. (2021). COVID-19 Pandemic and Investor Herding in International Stock Markets. *Herding in International Stock Risks 9: 168.*, 2-11.

- Boyd, J. H., Hu, J., & Jagannathan, R. (2005). The Stock Market's Reaction to Unemployment News: Why Bad News Is Usually Good for Stocks. *The Journal of Finance*, Vol. 60, No. 2, 649-672.
- Brown, S. J., & Warner, J. B. (1985). Using Daily Stock Returns: The Case of Event Studies*. *Journal of Financial Economics*, Vol. 14, 3-31.
- Bui, V. X., & Nguyen, H. T. (2019). Stock market activity and Google Trends: the case of a developing economy. *Journal of Economics and Development* Vol. 21 No. 2, 191-212.
- Burggraf, T., Duc, T. L., Rudolf, M., & Wang, M. (2020). Do FEARS drive Bitcoin? *Review of Behavioral Finance*, 1-31.
- Bustamante, M. D., Hernández del Valle, A., & Ortiz Ramírez, A. (2019). The Google trends effect on the behavior of the exchange rate Mexican peso - US dollar. *Contaduría y Administración* 64 (2), 1-14.
- Campbell, C. J., Cowan, A. R., & Salotti, V. (2010). Multi-Country Event Study Methods. *Journal of Banking & Finance*, Vol. 34, 3078–3090.
- Campbell, C., & Wasley, C. (1992). Measuring security price performance using daily NASDAQ returns. *Journal of Financial Economics*, Vol. 33, 73-92.
- Cao, M. M., Nguyen, N.-T., & Tran, T.-T. (2021). Behavioral Factors on Individual Investors' Decision Making and Investment Performance: A Survey from the Vietnam Stock Market. *Journal of Asian Finance, Economics and Business* Vol 8 No 3, 845–0853.
- Cappiello, L., & Guéné, S. (2005). Measuring Market and Inflation Risk Premia in France and in Germany. *European Central bank, Working papers series*, Nro. 436, 1-35.
- Carhart, M. (1997). On Persistence in Mutual Fund Performance. *The Journal of Finance*, Vol. 52, Nro. 1., 57-82.
- Carmona Muñoz, D., & Vera Leyton, M. (2015). Evaluación de factores de riesgo con influencia en los retornos de los activos de la canasta COLCAP en COLOMBIA., 2009-2012. *Revista Dimensión Empresarial*, vol. 13, núm. 1., 21-40.

- Carriere-Swallow, Y., & Labbé, F. (2011). Nowcasting with Google Trends in an Emerging Market. *Journal of Forecasting J. Forecast.*, 1-13.
- Castillo, A. (2004). The announcement effect of bond and equity issues: evidence from Chile. *Cuadernos de Economía, Vol. 31 No. 2*, 177–205.
- Cebrián, E., & Domenech, J. (2022). Is Google Trends a quality data source? *Applied Economics Letters*, 1-5.
- Celis, C., & Maturana, G. (1998). Initial public offerings in Chile. *Abante, Vol. 1, Nro. 1*, 7-31.
- Chahuán-Jiménez, K., & Riffo Rosas, M. (2022). Sentiment analysis in financial markets in a disruptive environment. *CAPIC Review, Journal Of Accounting, Auditing And Business Management*, 1-11.
- Challet, D., & Hadj Ayed, A. B. (2020). Do Google Trend data contain more predictability than price returns? *Journal of Investment Strategies, Arthur Berd*, 1-16.
- Chan, H., & Faff, R. (2005). Asset Pricing and the Illiquidity Premium. *The Financial Review* 40, 429--458.
- Chan, K. C., & Chen, N.-F. (1991). Structural and Return Characteristics of Small and Large Firms. *The Journal of Finance, Vol. 46, No. 4.*, 1467-1484.
- Chandra, A., & Thenmozhi, M. (2017). Behavioural Asset Pricing: Review and Synthesis. *Journal of Interdisciplinary Economics* 29(1), 1-31.
- Chaudhary, P. (2016). *Test of CAPM: A Study of India and US*. Delhi, India: Shri Ram College of Commerce.
- Chaudhary, R., Bakhshi, P., & Gupta, H. (2020). Volatility in International Stock Markets: An Empirical Study during COVID-19. *Journal of Risk and Financial Management* ·13, 208, 1-27.
- Chen, H., Shan, L., & Wang, C. (2021). Investment Sentiment in Finance Market. *Advances in Economics, Business and Management Research, volume 203*, 3325-3332.
- Chen, M.-H., Jang, S., & Kim, W. G. (2007). The impact of the SARS outbreak on Taiwanese hotel stock performance: An event-study approach. *Hospitality Management, Vol. 26*, 200–212.

- Chen, N.-f., & Zhang, F. (1998). Risk and Return of Value Stocks. *The Journal of Business*, Vol. 71, No. 4., 501-535.
- Chen, S. T., & Haga, K. Y. (2021). Using E-GARCH to Analyze the Impact of Investor Sentiment on Stock Returns Near Stock Market Crashes. *Psychol.*, 27, 1-16.
- Chen, S., Gao, T., He, Y., & Jin, Y. (2019). Predicting the Stock Price Movement by Social Media Analysis. *Journal of Data Analysis and Information Processing*, 2019, 7, 295-305.
- Chen, X., & Ray-Wang, N. (2020). Revisiting Fama–French’s asset pricing model with an MCB volatility risk factor. *Journal of Risk Finance*, Vol. 21 No. 3, 233-251.
- Chile, B. C. (2020). *Informe de Política Monetaria*. Santiago de Chile: Banco Central de Chile.
- Chile, B. d. (06 de 10 de 2021). *Bolsa de Santiago*. Obtenido de Bolsa de Santiago: <https://www.bolsadesantiago.com/>
- Chile, C. (05 de Mayo de 2020). *Cnnchile*. Obtenido de Cnnchile: https://www.cnnchile.com/coronavirus/hitos-claves-covid-19-chile-mundo-cronologia_20200505/
- Cole, B., Daigle, J., & Van Ness, B. F. (2015). Do Tweets Matter for Shareholders? An Empirical Analysis. *Journal of Accounting and Finance* Vol. 15(3), 39-51.
- Coronado, S., Martinez, J. N., Gualajara, V., & Rojas, O. (2022). Transfer Entropy Granger Causality between News Indices and Stock Markets in U.S. and Latin America during the COVID-19 Pandemic. *Entropy*, 1-10.
- Corrado, C. J. (1989). A nonparametric test for abnormal security-price performance in event studies. *Journal of financial economics*, Vol. 23, 385-305.
- Corrado, C. J., & Zivney, T. L. (1992). The Specification and Power of the Sign Test in Event Study Hypothesis Tests Using Daily Stock. *The Journal of Financial and Quantitative Analysis*, Vol. 27, 465-478.
- Corsi, F. (2009). A Simple Approximate Long-Memory Model of Realized Volatility. *ournal of Financial Econometrics*, 2009, Vol. 7, No. 2, 174–196.

- Costola, M., Iacopini, M., & Santagiustina, C. R. (2021). Google search volumes and the financial markets during the COVID-19 outbreak. *Finance Research Letters* 42, 1-7.
- COVID-19, C. P. (15 de 11 de 2021). *Coronavirus Pandemic (COVID-19)*. Obtenido de Coronavirus Pandemic (COVID-19): <https://ourworldindata.org/coronavirus>
- Curme, C., Preis, T., Stanley, H. E., & Moat, H. S. (2013). Quantifying the semantics of search behavior before stock market moves. *PNAS Vol 111, Nro 32.*, 11600–11605.
- Czupryna, M., Kubińska, E., & Markiewicz, Ł. (2015). What Makes Technical Analysis Popular? *AOC, 2015; 12*, 53–66.
- Da, Z., Engelberg, J., & Gao, P. (2011). In Search of Attention. *The Journal of Finance* • Vol. LXVI, Nro. 5, 1463-1493.
- Damodaran, A. (2002). *Estimating Risk Parameters*. New York: Stern School of Business.
- Daniel, K., & Titman, S. (1997). Evidence on the Characteristics of Cross Sectional Variation in Stock Return. *The Journal of Finance, Vol. 52, Nro. 1.*, 1-33.
- Danks, D., & Plis, S. (2013). Learning Causal Structure from Undersampled Time Series. *JMLR: Workshop and Conference Proceedings 1*, 1-10.
- De Bondt, W., & Thaler, R. (1985). *Does the Stock Market Overreact?* Chicago: The Journal of Finance VOL. XL, NO. 3 JULY 1985.
- De Carvalho, G. A., Fernandes Amaral, H., Lima Pinheiro, J., & Ferraz Correia, L. (2021). The pricing of anomalies using factor models: a test in Latin American markets. *R. Cont. Fin. – USP, São Paulo, v. 32, n. 87*, 492-509.
- De la Torre-Torres, Ó. V. (2020). COVID-19 news and volatility contagion in the Mexican stock market. *Contaduría y Administración 65 (5), Especial COVID-19*, 1-29.
- De la Torre-Torres, O. V., Bollain-Parra, L., & Durán-Sánchez, A. (2022). The Impact of COVID-19 News and Investor Sentiment in European Stock Pricing, a Regional, Country, and Economic Sector Review. *Revista Portuguesa de Estudos Regionais, nro. 60*, 165-177.

- Dellavigna, S., & Pollet, J. M. (2009). Investor Inattention and Friday Earnings Announcements. *The Journal of Finance*, Vol. LXIV, Nro. 2, 709-749.
- Derya, G. (2021). The Impact of Investor Sentiment on Bitcoin Returns and Conditional Volatilities during the Era of Covid-19. *Journal of Behavioral Finance*, 1-14.
- Dey, A. K., Hoque, G. M., & Das, K. P. (2020). Quantifying the impact of COVID-19 on the US stock market: An analysis from multi-source information. *arXiv Vol 3.*, 1-28.
- Dey, A. K., Hoque, G. T., Das, K. P., & Panovska, I. (2022). Impacts of COVID-19 local spread and Google search trend on the US stock market. *Physica A* 589, 1-17.
- Dharani, M., Hassan, M. K., Abedin, M. Z., & Ismail, M. A. (2022). Does a search attention index explain portfolio returns in India? *Borsa Istanbul Review Volume 22, Issue 2*, 226-239.
- Díaz Contreras, C. A., & Higuera Cartes, F. H. (2012). Contraste empírico del CAPM en el mercado accionario chileno. *Ingeniare. Revista chilena de ingeniería*, vol. 20 Nro. 2, 255-266.
- Díaz, F., & Henríquez, P. A. (2021). Social sentiment segregation: Evidence from Twitter and Google Trends in Chile during the COVID-19 dynamic quarantine strategy. *PLoS ONE* 16(7), 1-29.
- Díaz, V., Ibrushi, D., & Zhao, J. (2021). Reconsidering systematic factors during the Covid-19 pandemic – The rising importance of ESG. *Finance Research Letters*. Vol 38., 1-6.
- Dickey, D., & Fuller, W. (1979). *Distribution of the Estimators for Autoregressive Time Series With a Unit Root*. EEUU: Journal of The American Statistical Association.
- Dimpfl, T., & Jank, S. (2016). Can Internet Search Queries Help to Predict Stock Market Volatility? *European Financial Management*, Vol. 22, No. 2, 171–192.
- Ding, D., Guan, C., Chan, C. M., & Liu, W. (2020). Building stock market resilience through digital transformation: using Google trends to analyze the impact of COVID-19 pandemic. *Ding et al. Frontiers of Business Research in China* 14, 1-21.

- Dirkx, P., & Peter, F. (2020). The Fama-French Five-Factor Model Plus Momentum: Evidence for the German Market. *Schmalenbach Bus Rev* 72, 661–684.
- Dong, Z., Li, Y., Zhuang, X., & Wang, J. (2022). Impacts of COVID-19 on global stock sectors: Evidence from time-varying connectedness and asymmetric nexus analysis. *North American Journal of Economics and Finance* 62, 1-22.
- Doria, C. F., & Nuñez, W. N. (2020). El mercado integrado latinoamericano - MILA - en tiempo de Covid-19. *Revista Aglala*. Vol. 11, 17-37.
- Dospatliev, L., Ivanova, M., & Varbanov, M. (2022). Effects of COVID-19 Pandemic on the Bulgarian Stock Market Returns. *Axioms* 2022, 11, 94, 1-15.
- Drake, M. S., Roulstone, D. T., & Thornock, J. R. (2012). Investor Information Demand: Evidence from Google Searches Around Earnings Announcements. *Journal of Accounting Research*, 1-40.
- Duarte, J. B. (2014). *Comprobación de la Eficiencia Débil en los Principales Mercados Financieros Latinoamericanos*. Madrid: Tesis Doctoral- Universidad Complutense de Madrid.
- Duarte, J. J., & Mascareñas, J. M. (2014). Comprobación de la eficiencia débil en los principales mercados. *Estudios Gerenciales*, Vol 30, 365-375.
- Durand, R. B., Lim, D., & Zumwalt, J. K. (2011). Fear and the Fama-French Factors. *the Financial Management Association International*, 409-426.
- Duz Tan, S., & Tas, O. (2020). Social Media Sentiment in International Stock Returns and Trading Activity. *Journal of Behavioral Finance*, 2-15.
- Eachempati, P., Srivastava, P. R., & Panigrahi, P. K. (2021). Sentiment Analysis of COVID-19 Pandemic on the Stock Market. *American Business Review* Vol.24 (1), 141-165.
- Eichenauer, V. Z., Indergand, R., Martínez, I. Z., & Sax, C. (2022). Obtaining consistent time series from Google Trends. *Economic Inquiry* 60, 694–705.
- Elbannan, M. A. (2015). The Capital Asset Pricing Model: An Overview of the Theory. *International Journal of Economics and Finance*; Vol. 7, No. 1, 2016-228.

- Elton, E. J., Gruber, M. J., & Busse, J. A. (2002). Are Investors Rational? Choices Among Index Funds. *NYU Working Paper*, 1-35.
- Emre, C., Buket Kirci, A., Cevik, E., & Sel, D. (2022). Investor sentiments and stock markets during the COVID-19 pandemic. *Cevik et al. Financial Innovation*, 8:69.
- Erdős, P., Ormos, M., & Zibriczky, D. (2011). Non-parametric and semi-parametric asset pricing. *Economic Modelling* 28, 1150-1162.
- Evangelos, V. (2020). Efficient Markets Hypothesis in the Time of COVID-19. *Review of Economic Analysis*, Vol 13, 45-62.
- Fama, E. F., & French, K. R. (1995). *Size and Book-to-Market Factors in Earnings and Returns*. Chicago, EEUU: The Journal of Finance.
- Fama, E. F., Fisher, L., Jensen, M. C., & Roll, R. (1969). The Adjustment of Stock Prices to New Information. *International Economic Review*, Vol. 10, 1-21.
- Fama, E., & French, K. (2006). Profitability, investment and average returns. *Journal of Financial Economics* 82, 491–518.
- Fama, E., & French, K. (2015). A five factor asset pricing model. *Journal of Financial Economics* 116, 1-22.
- Fama, E., & French, K. (1996). *The CAPM is Wanted, Dead or Alive*. EEUU: The Journal of Finance, Vol. 51, No. 5 (Dec., 1996), pp. 1947-1958.
- Fama, E., & MacBeth, J. (1973). *Risk, return, and equilibrium: Empirical tests*. EEUU: The Journal of Political Economy, pp. 607-36.
- Fama, Eugene. (1965). *Random Walks in Stocks Market Prices*. Chicago, EEUU: Graduate School Of Business, The University of Chicago.
- Fama, Eugene. (1965). The Behavior of Stock-Market Prices. *The Journal of Business*, 34-105.
- Fama, Eugene. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance* Vol. 25, No. 2, 383-417.
- Fama, Eugene. (1991). Efficient Capital Markets II. *The Journal of Finance* Vol. 46, 1575-1617.

- Fama, Eugene F.; French, Kenneth R. (2004). The Capital Asset Pricing Model: Theory and Evidence. *Journal of Economic Perspectives*, Volume 18, Number 3, 25–46.
- Fama, Eugene; Crum, Roy. (1977). *On the Use of the CAPM in Public Utility Rate Cases*. Washington, EEUU: Financial Management Association.
- Fama, Eugene; French, Kenneth. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics* 33, 3-56.
- Fama, Eugene; French, Kenneth. (1996). Multifactor Explanations of Asset Pricing Anomalies. *The Journal of Finance*, Vol. 51, No. 1, 55-84.
- Fama, Eugene; MacBeth, James. (1973). *Risk, Return, and Equilibrium: Empirical Tests*. Chicago, EEUU: The Journal of Political Economy, Vol. 81, No. 3. (May - Jun., 1973), pp. 607-636.
- Fauzi, F., Santi, F., Anuar, S., & Citrawati, J. (2019). Google Search Volume And Investors' Decision On Return And Liquidity In Indonesia. *Opción*, Año 35, No. 88, 644-684.
- Person, W. E., Sarkissian, S., & Simin, T. (1999). The alpha factor asset pricing model: A parable. *Journal of Financial Markets* 2, 49-68.
- Feyyaz, Z., Tayfun, Y., & Murat, B. (2019). Testing the validity of Fama French Five Factor Asset Pricing Model: Evidence from Turkey. *Romanian Academy, National Institute of Economic Research (INCE)*. Vol. 23., 98-113.
- Filiz, I., Nahmer, T., Spiwoks, M., & Bizer, K. (2018). Portfolio diversification: the influence of herding, status-quo bias, and the gambler's fallacy. *Financ Mark Portf Manag*, Vol 32, 167–205.
- Foye, J. (2018). A comprehensive test of the Fama-French five-factor model in emerging markets. *Emerging Markets Review*. Vol. 37., 199-222.
- Fromlet, H. (2001). Behavioral Finance-Theory and Practical Application. *Business Economics*, Vol. 36, No. 3, 63-69.
- Funakoshi, M., & Hartman, T. (23 de Marzo de 2020). *Mad March: how the stock market is being hit by COVID-19*. Recuperado el 20 de 05 de 2021, de <https://www.weforum.org/>:

<https://www.weforum.org/agenda/2020/03/stock-market-volatility-coronavirus/>

- Garcia-Moreno, M. B., Roldán, J. A., & Daniel, C. (2019). La influencia de la crisis financiera en la eficiencia de los mercados Latinoamericanos: un análisis empírico. *Revista ESPACIOS. ISSN 0798 1015 Vol 40. Nro. 10*, 1-16.
- Garnia, E., Riadi, D. R., Tahmat, T., & Arieana, F. D. (2021). Macroeconomic Factor Impact on the Stock Returns: An Empirical Study on the Indonesia LQ45 Stocks. *Advances in Economics, Business and Management Research, volume 192*, 133-137.
- Gharghori, P., Chan, H., & Faff, R. (2007). Are the Fama-French Factors Proxying Default Risk? *Australian Journal of Management, Vol. 32, Nro. 2.*, 223-249.
- Gherghina, C. S., Armeanu, S. D., & Joldes, C. C. (2021). COVID-19 Pandemic and Romanian Stock Market Volatility: A GARCH Approach. *Journal of Risk and Financial vol 14*, 2-29.
- Ghoul, S. E., Guedhami, O., Mansi, S. A., & Sy, O. (2022). Event studies in international finance research. *Journal of International Business Studies*, 1-21.
- Gibbons, M. R., Ross, S. A., & Shanken, J. (1989). A test of efficiency of a given portfolio. *EEUU: Econometrics, Vol. 57, No. 5 (September, 1989)*, 1121-1152.
- Gkillas, K., Konstantatos, C., & Siriopoulos, C. (2021). Uncertainty Due to Infectious Diseases and Stock–Bond Correlation. *Econometrics 9(2), 17*, 1-18.
- Gómez Jacinto, L. G. (2014). Factores determinantes de la estructura de capital: Evidencia del mercados de valores Peruano. <https://www.researchgate.net/publication/270583322>, 1-20.
- Gómez-Mejía, A. (2020). Modelo de máxima verosimilitud . *Libre Empresa vol. 17, No. 2*, 1-18.
- González Maiz Jiménez, J., & Ortiz Calisto, E. (2020). Testing the overreaction hypothesis in the mexican stock market. *Contaduría y Administración 65 (1)*, 1-23.

- González-Sánchez, M. (2021). Asset pricing models in emerging markets: Factorial approaches vs. information stochastic discount factor. *Finance Research Letters Vol 1*, 1-9.
- Granger, C. (1969). *Investigating Causal Relations by Econometric Models and Cross-spectral Methods*. New York: Econometric Society.
- Greene, W. (2002). *Fixed and Random Effects in Stochastic Frontier Models*. New York: Department of Economics, Stern School of Business, New York University.
- Groß-Klußmann, A., König, S., & Ebner, M. (2019). Buzzwords build momentum: Global financial Twitter sentiment and the aggregate stock market. *Expert Systems With Applications 136*, 171-186.
- Grossman, S. J., & Stiglitz, J. E. (1980). On the Impossibility of Informationally Efficient Markets. *The American Economic Review, Vol. 70, No. 3*, 393-408.
- Guan, C., Liu, W., & Cheng, J. Y.-C. (2022). Using Social Media to Predict the Stock Market Crash and Rebound amid the Pandemic: The Digital 'Haves' and 'Have-mores'. *Annals of Data Science 9(1)*; 5–31.
- Gujarati, D., & Porter, D. (2009). *Econometría, Quinta Edición, Páginas 738, 768*. EEUU: Mc Graw Hill, Educación.
- Güler, D. (2021). The Impact of Investor Sentiment on Bitcoin Returns and Conditional Volatilities during the Era of Covid-19. *Journal of Behavioral Finance*, 1-14.
- Hamid, A., & Heiden, M. (2015). Forecasting volatility with empirical similarity and Google Trends. *Journal of Economic Behavior & Organization 117*, 62–81.
- Harshita, S., & Surendra, Y. (2015). Indian stock market and the asset pricing models. *Procedia Economics and Finance 30*, 294–304.
- Harvey, C. R. (1995). Predictable Risk and Returns in Emerging Markets. *The Review of Financial Studies Vol 8. Nro 3.*, 773-816.
- Hassan, H., & Kayser, S. (2019). Ramadan effect on stock market return and trade volume: Evidence from Dhaka Stock Exchange (DSE). *Cogent Economics & Finance*, 1-10.

- Hausman, J. A. (1978). Specification Tests in Econometrics. *Econometrica*, Vol. 46, No. 6, 1251-1271.
- Hendricks, D., Patel, J., & Zeckhauser, R. (1993). Hot Hands in Mutual Funds: Short-Run Persistence of Relative Performance, 1974-1988. *The Journal of Finance*, Vol. 48, Nro. 1., 93-130.
- Hensler, D. A., Herrera, M. J., & Lockwood, L. J. (2000). The performance of initial public offerings in the Mexican stock market, 1987–1993. *Journal of International Money and Finance* 19, 93–116.
- Herwany, A., Febrian, E., Anwar, M., & Gunardi, A. (2021). The Influence of the COVID-19 Pandemic on Stock Market Returns in Indonesia Stock Exchange. *Journal of Asian Finance, Economics and Business* Vol 8 No 3, 39–47.
- Hirshleifer, D. (2001). Investor Psychology and Asset Pricing. *The Journal of Finance*, Vol. 56, No. 4, 1533-1597.
- Hitz, L., Mustafi, I. H., & Zimmermann, H. (2022). The pricing of volatility risk in the US equity market. *International Review of Financial Analysis* 79, 1-22.
- Hoerl, A. E., & Kennard, R. W. (1970). Ridge Regression: Biased Estimation for Nonorthogonal Problems. *Technometrics*, Vol. 12, No. 1, 55-67.
- Horváth, D., & Wang, Y.-L. (2021). The examination of Fama-French Model during the Covid-19. *Finance Research Letters*. Vol. 41, 1-7.
- Hou, Kewei; Xue, Chen; Zhang, Lu. (2014). Digesting Anomalies: An Investment Approach. *Published by Oxford University Press on behalf of The Society for Financial Studies*, 651-705.
- Houlihan, P., & Creamer, G. G. (2017). Risk Premium of Social Media Sentiment. *Journal of Investing* 26 (3), 21-28.
- Huang, M. Y., Rojas, R. R., & Convery, P. D. (2019). Forecasting stockmarket movements using Google Trend searches. *Empir Econ* 59, 1-19.
- Huang, T.-L. (2019). Is the Fama and French five-factor model robust in the Chinese stock market? *Asia Pacific Management Review*, Vol. 24., 278e289.
- Huberman, G., & Kandel, S. (1987). Mean-Variance Spanning. *The Journal of Finance*, Vol. 42, No. 4, 873-888.

- Huynh, T., Foglia, M., Nasir, M., & Angelini, E. (2021). Feverish sentiment and global equity markets during the COVID-19 pandemic. *Journal of Economic Behavior and Organization* 188, 1088-1108.
- Hyttinen, A., Plis, S., Järvisalo, M., Eberhardt, F., & Danks, D. (2017). A constraint optimization approach to causal discovery from subsampled time series data. *International Journal of Approximate Reasoning* 90, 208-225.
- Infante, M. P. (20 de Enero de 2018). Fondos de pensiones solo son dueños del 8,6% del valor en bolsa de empresas del IPSA. *Economía y Negocios*, pág. <http://www.economiaynegocios.cl/noticias/noticias.asp?id=439000>.
- Insaidoo, M., Arthur, L., Amoako, S., & Andoh, F. K. (2021). Stock market performance and COVID-19 pandemic: evidence from a developing economy. *Journal of Chinese Economic and Foreign Trade Studies* Vol. 14 No. 1, 60-73.
- Inversiones, E. E. (12 de Junio de 2018). Las AFP registran la mayor compra en acciones chilenas en casi dos años. *El Mercurio*, págs. <http://www.elmercurio.com/Inversiones/Noticias/Analisis/2018/06/11/Ranking-Portafolio-de-las-AFP-en-mayo.aspx>.
- Investing.com. (15 de 11 de 2021). *Investing.com*. Obtenido de Investing.com: <https://es.investing.com/>
- Jan, N., Li, Z., & Xiyu, L. (2022). Pre- and post-COVID-19: The impact of the pandemic and stock market psychology on the growth and sustainability of consumer goods industries. *Frontiers in Psychology*, 1-17.
- Javid, A. Y., & Ahmad, E. (2012). Testing Multifactor Capital Asset Pricing Model in Case of Pakistani Market. *MPRA Paper No. 37341*, 1-28.
- Jegadeesh, N., Noh, J., Pukthuanthong, K., Roll, R., & Wang, J. (2019). Empirical Tests of Asset Pricing Models with Individual Assets: Resolving the Errors-in-Variables Bias in Risk Premium Estimation. *Journal of Financial Economics*, 1-87.
- Ji, X., Bu, N., Zheng, C., Xiao, H., Liu, C., Chen, X., & Wang, K. (2022). Stock market reaction to the COVID-19 pandemic: an event study. *Portuguese Economic Journal*, 1-20.

- Jiang, B., Zhu, H., Zhang, J., Yan, C., & Shen, R. (2021). Investor Sentiment and Stock Returns During the COVID-19 Pandemic. *Front. Psychol.* 12:708537, 1-5.
- Jordan, D. M. (2012). *Grau d'Estadística Aplicada*. Barcelona, España: Universidad Autónoma de Barcelona.
- Jun, S.-P., Yoo, H. S., & Choi, S. (2018). Ten years of research change using Google Trends: From the perspective of big data utilizations and applications. *Technological Forecasting & Social Change* 130, 69-87.
- Just, M., & Echaust, K. (2020). Stock market returns, volatility, correlation and liquidity during the COVID-19 crisis: Evidence from the Markov switching approach. *Finance Research Letters* 37, 1-8.
- Kahneman, D., & Tversky, A. (1979). Prospect Theory: An Analysis of Decision under Risk. *Econometrica*, Vol. 47, No. 2, 263-292.
- Karakoc, B. (2016). A Validity Analysis of Capital Asset Pricing Model (CAPM) in Istanbul Stock Exchange. *Journal of Social Sciences of Muş Alparslan University*. Vol 4, Nro: 1, 46-56.
- Karamera, O. K. (1999). Random walks and market efficiency test of Latin American emerging equity markets. *The Financial Review*, 34, 57-72.
- Kendall, M., & Bradford Hill, A. (1953). The Analysis of Economic Time-Series-Part I: Prices. *Journal of the Royal Statistical Society. Series A (General)*, Vol. 116, 11-34.
- Kim, E.-H., & Youm, Y. (2017). How Do Social Media Affect Analyst Stock Recommendations? Evidence from S&P 500 Electric Power Companies' Twitter Accounts. *Strategic Management Journal Volume38, Issue13*, 2599-2622.
- Kim, J. H., & Shamsuddin, A. (2017). Empirical Validity of Asset-pricing Models: Application of Optimal Significance Level and Equal Probability Test. *Available; <https://ssrn.com/abstract=2851370>* , 1-40.
- Kim, N., Luřcivjanská, K., Molnár, P., & Villa, R. (2018). Google searches and stock market activity: evidence from Norway. *Finance Research Letters*, 1-15.

- Kolasani, S. V., & Assaf, R. (2020). Predicting Stock Movement Using Sentiment Analysis of Twitter Feed with Neural Networks. *Journal of Data Analysis and Information Processing, Vol 8*, 309-319.
- Kostin, K. B., Runge, P., & Mamedova, L. E. (2023). Validity of the Fama-French Three- and Five-Factor Models in Crisis Settings at the Example of Select Energy-Sector Companies during the COVID-19 Pandemic. *Mathematics*, 1-13.
- Kownatzki, C. (2016). How Good is the VIX as a Predictor of Market Risk? *Journal of Accounting and Finance, Vol 16*, 2158-3625.
- Kräussl, R. (2005). Do credit rating agencies add to the dynamics of emerging market crises? *Journal of Financial Stability 1*, 355–385.
- Kubota, K., & Takehara, H. (2017). Does the Fama and French FiveFactor Model Work Well in Japan? *International Review of Finance*, 2-10.
- Kudryavtsev, A., Cohen, G., & Hon-Snir, S. (2013). “Rational” or “Intuitive”: Are Behavioral Biases Correlated Across Stock Market Investors? *Contemporary Economics, Vol 7*, 31-53.
- Lai, H.-H., Chang, T.-P., Hu, C.-H., & Chou, P.-C. (2021). Can google search volume index predict the returns and trading volumes of stocks in a retail investor dominant market. *Cogent Economics & Finance (2022), 10*, 1-18.
- Lakonishok, J., Shleifer, A., & Vishny, R. W. (1994). Contrarian Investment, Extrapolation, and Risk. *The Journal of Finance Vol. XLIX, NO. 5*.
- Lalwani, V., & Meshram, V. (2020). Stock Market Efficiency in the Time of COVID-19: Evidence from Industry Stock Returns . *International Journal of Accounting & Finance Review; Vol. 5, No. 2*, 40-44.
- Langa, E. S., Massuanganhe, J. A., & Nhanala, G. A. (2022). O Impacto do Coronavirus (COVID-19) e as Mudanças Climática na Taxa de Câmbio. *Prometeica Vol 24*, 210-226.
- Lazzini, A., Lazzini, S., Balluchi, F., & Mazza, M. (2021). Emotions, moods and hyperreality: social media and the stock market during the first phase of COVID-19 pandemic. *Accounting, Auditing & Accountability Journal, Vol 1*, 3-17.

- Le, T. P., & Tran, H. L. (2021). The Contagion Effect from U.S. Stock Market to the Vietnamese and the Philippine Stock Markets: The Evidence of DCC – GARCH Model. *Journal of Asian Finance, Economics and Business Vol 8 No 2*, 759–770.
- Leite, A. L., Klotzle, M. C., Figueiredo Pinto, A. C., & da Silveira Barbedo, C. H. (2020). The Fama-French's five-factor model relation with interest rates and macro variables. *North American Journal of Economics and Finance*.
- Leite, A. L., Klotzle, M. C., Figueiredo, A. C., & Ferreira, A. (2018). Size, value, profitability, and investment: Evidence from emerging markets. *Emerging Markets Review. Vol. 36*, 45-59.
- Lexlatin. (10 de 01 de 2023). *Lexlatin*. Obtenido de Lexlatin: <https://lexlatin.com/reportajes/unificacion-de-bolsas-chile-colombia-peru-mayor-mercado-bursatil>
- Li, C. A., & Wang, J. C. (2013). The Influences of Greed and Fear on Fund Performance. *The International Journal of Business and Finance Research. Vol 7, Nro 5*, 47-57.
- Li, J. (2021). Research on Market Stock Index Prediction Based on Network Security and Deep Learning. *Hindawi Security and Communication Networks, Volume 2021, Article ID 5522375*, 1-8.
- Liammukda, A., Khamkong, M., Saenchan, L., & Hongsakulvasu, N. (2020). The Time-Varying Coefficient Fama - French Five Factor Model: A Case Study in the Return of Japan Portfolios. *Journal of Asian Finance, Economics and Business Vol 7. Nro 10*, 513–521.
- Lim, S. (2015). Feeling the Market's Pulse With Google Trends. *IFTA Journal*, 11-17.
- Lintner, J. (1965). The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets. *The Review of Economics and Statistics, Vol. 47, Nro. 1.*, 13-37.
- Lowen, C., Kchouri, B., & Lehnert, T. (2021). Is this time really different? Flight-to-safety and the COVID-19 crisis. *PLoS ONE 16(5)*, 1-17.

- Luzarraga, J., Regúlez, M., & Rodríguez, A. (2021). The dynamics between the stock market and exchange rates: Spain 1999–2015. *The European Journal of Finance*, Vol. 27, Nro. 7, 655-678.
- Lyócsa, Š., Baumöhl, E., Výrost, T., & Molnár, P. (2020). Fear of the coronavirus and the stock markets. *Leibniz Information Centre for Economics, Kiel, Hamburg*, 1-9.
- MacKinlay, A. (1997). Event Studies in Economics and Finance. *Journal of Economic Literature*, Vol. 35, No. 1., 13-39.
- MacKinnon, J. G. (2010). *Critical Values for Cointegration Tests*. Kingston, Ontario, Canada: Queen's Economics Department Working Paper No. 1227.
- Malkiel, B. (1973). *A Random Walk Down Wall Street*. New York: W. W. Norton & Company, Inc.
- Malkiel, B. G. (2003). The Efficient Market Hypothesis and Its Critics. *Journal of Economic Perspectives*, Vol. 17, Nro. 1., 59–82.
- Maquieira, C. V., & Osorio, D. M. (2000). Announcements of changes in dividend payments and their impact on shareholders' wealth: empirical evidence in Chile. *Estudios de Administración*, Vol. 7, Nro. 1, 1–26.
- Marín, J. M., & Gonzalo, R. (2011). *Economía Financiera*. Barcelona, España: Amoni Bosch editor, S.A.
- Markowitz, H. (1952). *Portfolio Selection*. EEUU: The Journal of Finance, Vol. 7, No. 1. (Mar., 1952), pp. 77-91.
- Martín Ugedo, J. F. (2003). *Metodología de los Estudios de Sucesos: Una revisión*. España: Investigaciones Europeas de Dirección y Economía de la Empresa.
- Mathur, I., Gleason, K. C., Dibooglu, S., & Singh, M. (2002). Contagion Effects from the 1994 mexican peso crisis: Evidence From Chilean Stocks. *The Financial Review* 37, 17.34.
- Matos, P., Costa, A., & da Silva, C. (2021). COVID-19, stock market and sectoral contagion in US: a time-frequency analysis. *Research in International Business and Finance* Vol 57., 1-14.

- Mendoza, R. A., García-Medina, A., & Nuñez, J. A. (2021). Measuring information flux between social media and stock prices with Transfer Entropy. *PLoS ONE* 16(9), 1-19.
- Mendoza-Urdiales, R. A., Nuñez-Mora, J. A., & Santillán-Salgado, R. J. (2022). Twitter Sentiment Analysis and Influence on Stock Performance Using Transfer Entropy and EGARCH Methods. *Entropy*, 1-17.
- Meneses Cerón, L., & Pérez Pacheco, C. (2020). Comparative analysis of efficiency in emerging markets. The case of Colombia, Chile and Peru. *Apuntes Contables nro. 26*, 9-24.
- Merton, R. C. (1987). A Simple Model of Capital Market Equilibrium with Incomplete Information. *The Journal of Finance*. Vol. XLII, Nro. 3, 483-510.
- Miller, M., & Modigliani, F. (1961). Dividend Policy, Growth, and the Valuation of Shares. *The Journal of Business*, Vol. 34, Nro. 4., 411-433.
- Mishra, R., Sharma, R., Karedla, Y., & Patel, N. (2022). Impact of COVID-19 Cases, Deaths, Stringency and Vaccinations on the US Stock Market . *SAGE Publications*, 1-13.
- Mondria, J., Wu, T., & Zhang, Y. (2010). The determinants of international investment and attention allocation: Using internet search query data. *Journal of International Economics* 82, 85–95.
- Montero, R. (2013). *Test de causalidad*. España: Documentos de Trabajo en Economía Aplicada. Universidad de Granada.
- Morán, P. V. (2003). Looking back at the controversy: unexpected wealth effects of a transitory cause. *Abante vol. 6, issue 2*, 117-147.
- Mossin, J. (1966). Equilibrium in a Capital Asset Market. *Econometrica*, Vol. 34, No. 4, 768-783.
- Mukoyi, L., & Ogujiuba, K. K. (2022). Comparison of Multifactor Asset Pricing Models in the South African Stock Market [2000–2016]. *Journal of Risk and Financial Management* 16: 4., 1-22.
- Navratil, R., Taylor, S., & Vecer, J. (2021). On equity market inefficiency during the COVID-19 pandemic. *International Review of Financial Analysis Vol Nro. 77*, 1-9.

- Ndikum, P. (2020). Machine Learning Algorithms for Financial Asset Price Forecasting. *Saïd Business School University of Oxford*, 1-16.
- Nguyen, C., Schinckus, C., & Nguyen, T. (2019). Google search and stock returns in emerging markets. *Borsa Istanbul Review*, 1-9.
- Nippani, S., & Washer, K. M. (2004). SARS: a non-event for affected countries' stock. *Applied Financial Economics*, *Vo. 14*, 1105–1110.
- Novy-Marx, R. (2013). The Other Side of Value: The Gross Profitability Premium. *Journal of Financial Economics* 108, 1-28.
- Novy-Marx, Robert. (2012). Is momentum really momentum? *Journal of Financial Economics* 103, 429-453.
- OECD. (2021). *Artificial Intelligence, Machine Learning and Big Data in Finance: Opportunities, Challenges, and Implications for Policy Makers*. Paris: <https://www.oecd.org/finance/artificialintelligencemachinelearningbigdatafinance.htm> .
- Ojah, K., & Karemena, D. (1999). Random Walks and Market Efficiency Tests of Latin American Emerging Equity Markets: A Revisit. *The Financial Review* 34, 57-72.
- Ortiz, J. J. (2019). Las finanzas conductuales y la teoría del riesgo: ¿nuevos fundamentos para la gerencia financiera? *Criterio Libre • Vol. 17 • N.º 31*, 43-82.
- Ozkan, O. (2021). Impact of COVID-19 on stock market efficiency: Evidence from developed countries. *Research in International Business and Finance* 58, 1-11.
- Padungsaksawasdi, C., & Treepongkaruna, S. (2021). Chasing for information during the COVID-19 panic: The role of Google search on global stock market. *Cogent Economics & Finance*, 9:1,, 1-16.
- Pai, P.-F., Hong, L.-C., & Lin, K.-P. (2018). Using Internet Search Trends and Historical Trading Data for Predicting Stock Markets by the Least Squares Support Vector Regression Model. *Computational Intelligence and Neuroscience Volume 2018*, 1-16.

- Pandey, D. K., & Kumari, V. (2020). Event study on the reaction of the developed and emerging stock markets to the 2019-nCoV outbreak. *International Review of Economics and Finance*, 467–483.
- Parisi, F., & Pérez, D. (2000). Cambios en el rating de bonos y su efecto en los precios accionarios: el caso chileno. *Revista ABANTE*, Vol. 3, N^o 2, 249-273.
- Peterson, P. P. (1989). Event Studies: A Review of Issues and Methodology. *Quarterly Journal of Business and Economics*, Vol. 28, No. 3, 36-66.
- Phan, D. H., & Narayan, P. K. (2020). Country Responses and the Reaction of the Stock Market to COVID-19. *Emerging Markets Finance and Trade* 2020, Vol. 56, No. 10, 2138–2150.
- Phillips, P. C., & Perron, P. (1988). Testing for a unit root in time series regression. *Biometrika* 75, 2, 1-12.
- Phillips, P., & Ouliaris, S. (1990). Asymptotic Properties of Residual Based Tests for Cointegration. *Econometrica*, Vol. 58, No. 1, 165-193.
- Pierre, J. S., Klimkiewicz, M., Resom, A., & Kalampalikis, N. (2019). Trading the Stock Market using Google Search Volumes A Long Short-Term Memory Approach. *International Journal of Financial Engineering and Risk Management* 3(1):3, 1-21.
- Pinto Ramos, H., Mendes Ribeiro, K. K., & Scherer Perlin, M. (2017). The Forecasting Power of Internet Search Queries In The Brazilian Financial Market. *Revista de Administração Mackenzie – RAM*, 18(2), 184-210.
- Piñeiro, J., López, M. Á., Pérez, A. M., & Ribeiro, B. (2018). Does social network sentiment influence the relationship between the S&P 500 and gold returns? *International Review of Financial Analysis* V6, 1-29.
- Pradyot, R., & Ritanjali, M. (2023). Are Twitter sentiments during COVID-19 pandemic a critical determinant to predict stock market movements? A machine learning approach. *Scientific African* 19, 2-12.
- Preis, T., Moat, H. S., & Stanley, H. E. (2013). Quantifying Trading Behavior in Financial Markets Using Google Trends. *Scientific Reports* 3, 1684, 1-6.
- Ragab, N., Abdou, R., & Sakr, A. (2020). A Comparative Study between the Fama and French Three Model and the Fama and French Five Factor Model:

- Evidence from the Egyptian Stock Market. *International Journal of Economics and Finance*; Vol. 12, No. 1, 52-69.
- Rahman, M., Guotai, C., Gupta, A., Hossain, M., & Abedin, M. (2021). Impact of early COVID-19 pandemic on the US and European stock markets and volatility forecasting. *Economic Research-Ekonomska Istraživanja*, 1-18.
- Ramírez, L. B., Valencia, A. M., & Villalba, D. M. (2017). *Evaluación de la eficiencia en nivel débil de la información en los mercados de renta variable de los países pertenecientes al MILA 2011-2016: una estimación a partir del modelo de Tres Factores de Fama y French*. Colombia: Facultad de Ciencias Económicas y Sociales - Universidad de la Salle.
- Ramona, D., Razvan, S., & Costel, N. (2012). Reactions of the capital markets to the shocks before and during the global crisis. *MPRA Paper No. 41540*, 2-23.
- Rathnasekara, R. D. (2017). *Testing Stock Market Efficiency and the Asset Pricing Model: Some Evidence From Sri Lanka*. UK: The University of Huddersfield.
- Reddy, K., Ali Jibrán Qamar, M., Mirza, N., & Shi, F. (2020). Overreaction effect: evidence from an emerging market (Shanghai stock market). *International Journal of Managerial Finance*, 1-22.
- Rehman Muhammad, A. u. (2021). The impact of investor sentiment on returns, cash flows, discount rates, and performance. *Research Institute of Economics and Management, Southwestern University of Finance and Economics*, No. 555, 1-11.
- Rehman, M., Kang, S., Ahmad, N., & Vo, X. (2021). The impact of COVID-19 on the G7 stock markets: A time-frequency analysis . *North American Journal of Economics and Finance* 58, 1-10.
- Riveros, J. M., & Hassan, M. S. (2021). First to react is the last to forgive: Evidence from the stock market impact of COVID 19. *Journal of Risk and Financial Management* Vol. 14., 1-25.
- Robin, R. (2021). Death Infectious: Impact of the Coronavirus Disease (COVID-19) on Stock Returns. *Journal of Economics, Business, and Accountancy Ventura* Vol. 24, No. 1,, 95-104.

- Roll, Richard. (1977). A Critique Of The Asset Pricing Theory's Tests. *Journal of Financial Economics Volume 4, Issue 2*, 129-176.
- Romero, R., Coronado, S., & Ibañez, F. (2021). COVID-19 y causalidad en la volatilidad del mercado accionario chileno. *Estudios Gerenciales vol. 37, Nro. 159*, 242-250.
- Ross, S. A. (1976). The Arbitrage Theory of Capital Asset Pricing. *Journal of Economics Theory 13*, 341-360.
- Roy, R. (2021). A six-factor asset pricing model: The Japanese evidence. *Financial Planning Review, Vol, 4*, 1-18.
- Ruan, L. (2018). Research on Sustainable Development of the Stock Market Based on VIX Index. *Sustainability, 10*, 1-12.
- Rubinstein, M. (1976). The Valuation of Uncertain Income Streams and the Pricing of Options. *The Bell Journal of Economics, Vol. 7, Nro. 2.*, 407-425.
- Ruiz Dávila, B. D., & García Muñoz, G. (2020). Hipótesis de Mercados Eficientes y estrategias de inversión en el MILA: 2014-2019. *Análisis Económico, vol. XXXV, núm. 90*, 1-24.
- Ruiz Dávila, B., & García Muñoz, G. (2020). Efficient Market Hypothesis and investment strategies in MILA: 2014-2019. *Análisis Económico, vol. XXXV, núm. 90*, 67-90.
- Runge, J., Nowack, P., Kretschmer, M., Flaxman, S., & Sejdinovic, D. (2019). Detecting and quantifying causal associations in large nonlinear time series datasets. *Science Advances* , 1-15.
- Ryan, N., Ruan, X., Zhang, J., & Zhang, J. (2021). Choosing Factors for the Vietnamese Stock Market. *Journal of Risk and Financial Management Vol. 14.*, 1-23.
- Sadiq, M., Hsu, C.-C., Zhang, Y., & Chien, F. (2021). COVID-19 fear and volatility index movements: empirical insights from ASEAN stock markets. *Environmental Science and Pollution Research 28*, 67167–67184.
- Saens, R., & Sandoval, E. (2005). Measuring Security Price Performance Using Chilean Daily Stock Return: The Event Study Method. *Cuadernos de Economía, Vol 42*, 307-328.

- Saens, Rodrigo. (1999). Premia in emerging market ADR prices: Evidence from Chile. *Revista Abante*. Vol. 2. Nro. 1, 51-70.
- Said, B., Ur Rehman, S., Ullah, R., & Khan, J. (2021). Investor overreaction and global financial crisis: A case of Pakistan stock exchange. *Cogent Economics & Finance*, 9: 1966195, 2-18.
- Saiful, A., & Koji, S. (2020). Performance and Resilience of Socially Responsible Investing (SRI) and Conventional Funds during Different Shocks in 2016: Evidence from Japan. *Sustainability Vol 12, Nro 2.*, 1-20.
- Sakowski, P., Ślepaczuk, R., & Wywił, M. (2016). Applying exogenous variables and regime switching to multi-factor models on equity indices. *Ekonomia. Rynek, gospodarka, społeczeństwo* 47, 79–121.
- Samuelson, P. A. (1965). *Proof That Properly Anticipated Prices Fluctuate Randomly*. Boston, EEUU: Industrial Management Review.
- Sanjay Sehgal, A. P. (2018). Predicting Financial Crisis by Examining Risk-Return Relationship. *Theoretical Economics Letters*, vol 8, , 48-71.
- Sarwar, G. (2019). Transmission of Risk Between U.S. and Emerging Equity Markets. *Emerging Markets Finance & Trade*, 55, 1171–1183.
- Sato, K., Miyazaki, K., & Mawaribuchi, J. (2011). Simple Portfolio Strategies Utilizing Inflation Factor in Japanese Equity Market. *Procedia Computer Science* 4, 1716–1725.
- Saucedo, E., & González, J. (2021). The effect of macroeconomic variables on the robustness of the traditional Fama–French model. A study for Mexico using different portfolios. *Journal of Economics, Finance and Administrative Science Emerald Publishing Limited*, 1-16.
- Sepúlveda, J., Tapia, P., & Pastén, B. (2021). *Analyzing stock market signals for H1N1 and COVID-19: The BRIC case*. Santiago, Chile: Munich Personal RePEc Archive.
- Sewell, M. (2007). Behavioural Finance. *Department of Computer Science, University College London*, 1-14.

- Shahzad, S. J., Naeem, M. A., Peng, Z., & Bouri, E. (2021). Asymmetric volatility spillover among Chinese sectors during COVID-19. *International Review of Financial Analysis*, Vol. 75, 1-9.
- Sharpe, W. (1964). Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk. *The Journal of Finance*, Vol. 19, Nro. 3., 425-442.
- Sharpe, W. F. (1963). A Simplified Model for Portfolio Analysis. *Management Science* Vol. 9, No. 2, 277-293.
- Shefrin, H., & Statman, M. (1994). Behavioral Capital Asset Pricing Theory. *The Journal of Financial and Quantitative Analysis*, Vol. 29, No. 3, 323-349.
- Shiller, R. J. (2003). From Efficient Markets Theory to Behavioral Finance. *Journal of Economic Perspectives* Vol 18, Nro.1, 83-104.
- Sibley, S. E., Wang, Y., Xing, Y., & Zhang, X. (2016). The information content of the sentiment index. *Journal of Banking & Finance* 62, 164-179.
- Silva de Souza, D., & Silva Martins, O. (2022). Brazilian stock market performance and investor sentiment on Twitter. *Revista de Gestao Emerald Publishing Limited*, 1-16.
- Simon, H. A. (1971). Designing organizations for an information-rich world. *The Johns Hopkins Press, Baltimore. MD*, 40-41.
- Sims, C. A. (1980). *Macroeconomics and Reality*. EEUU: *Econometrica*, Vol. 48, No. 1 (Jan., 1980), pp. 1-48.
- Sims, C. A. (2003). Implications of rational inattention. *Journal of Monetary Economics* 50, 665–690.
- Singh, B., Dhall, R., Narang, S., & Rawat, S. (2020). The Outbreak of COVID-19 and Stock Market Responses: An Event Study and Panel Data Analysis for G-20 Countries. *Global Business Review* Vol Nro. 1, 1-26.
- Singh, R. (2008). CAPM vs. APT with Macro Economic Variables: Evidence from the Indian Stock Market. *Asia-Pacific Business Review* Volume IV, Number I, 76-92.
- Sin-Yi, C. T. (2011). *The Real World is Not Normal*. EEUU: Morningstar Alternative Investments Observer Third Quarter 2011.

- Smith, S., & O'Hare, A. (2022). Comparing traditional news and social media with stock price movements; which comes first, the news or the price change? *Journal of Big Data*, 9:47.
- Sobti, N. (2016). Revisiting CAPM and Fama French Three Factor Model. *Business Analyst Vol. 37*, 31-46.
- Statista. (04 de 05 de 2022). *statista.com*. Recuperado el 04 de 05 de 2022, de <https://es.statista.com>
- Subramaniam, S., & Chakraborty, M. (2021). COVID-19 fear index: does it matter for stock market returns? *Review of Behavioral Finance, Emerald Vol 13, Nro. 1*, 40-50.
- Takeda, F., & Wakao, T. (2014). Google search intensity and its relationship with returns and trading volume of Japanese stocks. *Pacific-Basin Finance Journal 27*, 1-18.
- Tapia, M., & Tokman, A. (2003). Efectos de las intervenciones en el mercado cambiario: el caso de Chile. *Estudios de Economía, Vol. 30, Nro. 1*, 21-53.
- Thaler, R. H. (1999). Mental Accounting Matters. *Journal of Behavioral Decision Making, 12*, 183-206.
- Tibshirani, R. (1996). Regression Shrinkage and Selection via the Lasso. *Journal of the Royal Statistical Society. Series B (Methodological), Vol. 58, No. 1*, 267-288.
- Tokić, S., Bolfek, B., & Peša, A. R. (2018). Testing Efficient Market Hypothesis in Developing Eastern European Countries. *Investment Management and Financial Innovations, Volume 15, Issue 2*, 281-291.
- Treynor, J. L. (1961). Market Value, Time, and Risk. Available at SSRN: <http://ssrn.com/abstract=628187>, 1-46.
- Trujillo, G. (2010). *La Metodología del Vector Autorregresivo: Presentación y Algunas Aplicaciones*. Perú: UCV - SCIENTIA.
- Tversky, A., & Kahneman, D. (1982). Judgment under Uncertainty: Heuristics and Biases. *Scienia, Vol. 185*, 1124-1131.
- Urrutia, J. (1995). Tests of random walk and market efficiency for Latin American emerging equity markets. *Journal of Financial Research, vol. 18, 3*, 299-309.

- Vasileiou, E., Samitas, A., Karagiannaki, M., & Dandu, J. (2021). Health risk and the efficient market hypothesis in the time of COVID-19. *International Review of Applied Economics*, Vol. 35, 210-223.
- Vassalou, M. (2003). News related to future GDP growth as a risk factor in equity returns. *Journal of Financial Economics* 68, 47–73.
- Vlastakis, N., & Markellos, R. N. (2012). Information demand and stock market volatility. *Journal of Banking & Finance* 36, 1808-1821.
- Von Neumann, J., & Morgenstern, O. (1947). *Theory of games and economic behavior*. EEUU: Princeton University Press.
- Wafi, A. S., Hassan, H., & Mabrouk, A. (2015). Fundamental Analysis Vs Technical Analysis in The Egyptian Stock Exchange – Empirical Study. *International Journal of Business and Management Study – IJBMS Volume 2 : Issue 2*, 212-218.
- Wajid, A., & Gupta, K. (2022). Stock Market Responses to the COVID-19 Health Crisis: Evidence From the World’s Largest Economies. *International Journal of Business Analytics Volume 9 • Issue 1*, 1-19.
- Wang, H., & Yu, Z. (2022). Chinese Stock Market’s Reaction to COVID-19 in the Short and Long Run. *Hindawi Complexity* , 1-18.
- Wang, J., & Wang, X. (2021). COVID-19 and financial market efficiency: Evidence from an entropy-based analysis . *Finance Research Letters* 42, 1-7.
- Wilson, B., Saunders, A., & Caprio, G. (2000). Mexico's Financial Sector Crisis: Propagative Linkages to Devaluation. *The Economic Journal*, Vol. 110, No. 460, 292-308.
- Worthington, A. C., & Higgs, H. (2003). Weak-form market efficiency in European emerging and developed stock markets. *School of Economics and Finance, Queensland University of Technology, Brisbane*, 1-17.
- Wu, X., Wang, X., Ma, S., & Ye, Q. (2017). The influence of social media on stock volatility. *Front. Eng. Manag.* 2017, 4(2), 201–211.
- Xiao, Y., Faff, R., Gharghori, P., & Lee, D. (2013). An Empirical Study of the World Price of Sustainability. *Journal of Banking & Finance*, 2-10.

- Xiao, Yuchao; Faff, Robert; Gharghori, Philip; Min, Byoung-Kyu. (2012). Pricing innovations in consumption growth: A re-evaluation of the recursive utility model. *Springer Science+Business Media B.V*, 297–310.
- Xiong, J. X., & Idzorek, T. M. (2011). The Impact of Skewness and Fat Tails on the Asset Allocation Decision. *Financial Analysts Journal*, Vol. 67, Nro. 2, 23-35.
- Xu, S., Zhang, J., & Shen, R. (2022). Uncertainty, Search Engine Data, and Stock Market Returns During a Pandemic. *Frontiers in Public Health*, Vol. 10., 1-5.
- Yan, H., Tu, A., Stuart, L., & Zhang, Q. (2020). *Analysis of the Effect of COVID-19 On the Stock Market and Potential Investing Strategies*. Illinois, EEUU: Gies School of Business, University of Illinois Urbana-Champaign.
- Yang, Z., Zhou, Y., & Xin, C. (2019). Systemic Risk in Global Volatility Spillover Networks:Evidence from Option-implied Volatility Indices. *The Journal of Futures Markets*, Forthcoming, 1-35.
- Yasmin, F. (2022). Testing and Determining the Form of Market Efficiency in Dhaka Stock Exchange (DSE). *International Journal of Accounting and Financial Reporting*, 60-75.
- Yousaf, I., Bouri, E., Ali, S., & Azoury, N. (2021). Gold against Asian Stock Markets during the COVID-19 Outbreak. *Journal of Risk and Financial Management*, Vol. 14, 2-23.
- Yu, G. (2020). Comparative Analysis of COVID-19 Trend, Impact on S&P 500, and S&P 500 Forecasting. *International Review of Business and Finance*, Volume 12, Nro. 1, 1-7.
- Yu, S. (2021). The impact of investor sentiment for the U.S. stock market based on Fama-French 3-factor model. *All issues Volume 275*, 1.4.
- Zapata, H. O., & Mukhopadhyay, S. (2022). A Bibliometric Analysis of Machine Learning Econometrics in Asset Pricing. *Journal of Risk and Financial Management* 15: 535, 1-17.
- Zheng, L. (1999). Is Money Smart? A Study of Mutual Fund Investors Fund Selection Ability. *The Journal of Finance*, Vol. 54, Nro. 3., 901-933.

Zou, H., & Hastie, T. (2005). Regularization and Variable Selection via the Elastic Net. *Journal of the Royal Statistical Society. Series B (Statistical Methodology)*, Vol. 67, No.2, 301-320.

Anexos

Anexo A:

Tabla A: Resultado de Análisis de Regresiones en dos pasos.

Acción	Constante	T-Value Constante	Beta Estimado	T-Value Beta Estimado	R cuadrado Ajustado	Std Error Regresión	Varianza de los Residuos	Retorno Promedio
AESGENER	-0,0037	-0,789	0,76	7,43	29,44%	0,0529	0,28%	0,043%
AGUAS-A	0,0014	0,402	0,44	5,68	19,38%	0,0399	0,16%	0,430%
ANDINA-B	0,0007	0,147	0,77	6,90	26,37%	0,0576	0,33%	0,486%
ANTARCHILE	-0,0036	-1,028	1,02	13,20	57,13%	0,0402	0,16%	0,145%
BCI	0,0031	0,706	0,92	9,66	41,54%	0,0495	0,24%	0,776%
BESALCO	0,0023	0,302	1,92	11,65	50,87%	0,0855	0,73%	1,068%
BSANTANDER	0,0004	0,106	0,83	9,79	42,19%	0,0438	0,19%	0,475%
CAP	-0,0080	-0,728	1,79	7,39	29,20%	0,1256	1,57%	-0,009%
CCU	0,0043	0,924	0,67	6,48	23,97%	0,0532	0,28%	0,805%
CENCOSUD	-0,0063	-1,403	1,31	13,14	56,92%	0,0515	0,26%	-0,021%
CHILE	0,0038	1,296	0,66	10,15	43,95%	0,0337	0,11%	0,754%
CMPC	-0,0041	-0,919	1,14	11,54	50,39%	0,0511	0,26%	0,138%
COLBUN	-0,0020	-0,443	0,78	7,96	32,41%	0,0511	0,26%	0,220%
CONCHATORO	-0,0028	-0,569	0,76	7,10	27,51%	0,0553	0,30%	0,133%
COPEC	-0,0027	-0,743	1,05	13,38	57,78%	0,0408	0,16%	0,252%
ECL	0,0046	0,725	1,01	7,24	28,33%	0,0721	0,52%	0,960%
EMBONOR-B	0,0045	0,905	0,69	6,37	23,34%	0,0564	0,32%	0,832%
ENELAM	-0,0064	-1,192	0,98	8,24	33,97%	0,0615	0,38%	-0,153%
ENELCHILE	-0,0024	-1,190	0,12	2,81	5,05%	0,0228	0,05%	-0,065%
ENELGXCH	-0,0061	-0,728	0,82	4,41	12,44%	0,0959	0,91%	-0,182%
ENTEL	-0,0033	-0,768	0,54	5,75	19,79%	0,0490	0,24%	-0,001%
FALABELLA	0,0029	0,701	0,95	10,50	45,65%	0,0470	0,22%	0,770%
FORUS	0,0053	0,763	1,39	9,02	38,22%	0,0798	0,63%	1,178%
IAM	0,0017	0,522	0,49	6,76	25,58%	0,0378	0,14%	0,483%
ILC	0,0008	0,202	0,40	4,54	13,11%	0,0453	0,20%	0,354%
ITAUCORP	0,0010	0,222	0,93	9,72	41,85%	0,0495	0,24%	0,568%
LTM	-0,0039	-0,708	1,27	10,39	45,15%	0,0633	0,40%	0,206%
MASISA	-0,0145	-2,003	1,55	9,71	41,77%	0,0825	0,68%	-0,747%
NUEVAPOLAR	-0,0358	-2,256	1,49	4,26	11,63%	0,1812	3,26%	-2,903%
OROBLANCO	0,0028	0,300	1,11	5,32	17,37%	0,1080	1,16%	0,824%
PARAUCO	0,0055	1,247	1,04	10,69	46,54%	0,0505	0,25%	1,067%
RIPLEY	-0,0067	-1,159	1,32	10,40	45,18%	0,0656	0,43%	-0,050%
SALFACORP	-0,0024	-0,313	1,70	10,09	43,69%	0,0871	0,75%	0,519%
SECURITY	-0,0005	-0,107	0,99	10,18	44,11%	0,0505	0,25%	0,448%
SK	0,0028	0,504	1,06	8,73	36,68%	0,0629	0,39%	0,799%
SM-CHILE B	0,0100	2,624	0,77	9,15	38,88%	0,0434	0,19%	1,411%
SMSAAM	-0,0019	-0,580	0,43	6,05	21,50%	0,0371	0,14%	0,099%
SONDA	-0,0005	-0,109	0,87	8,45	35,14%	0,0535	0,28%	0,400%
SQMB	0,0065	0,817	1,22	8,45	26,76%	0,0905	0,81%	1,227%
VAPORES	-0,0279	-3,202	1,89	9,86	42,53%	0,0994	0,98%	-1,959%

Tabla B: Resultados Análisis de Test BJS (10 Portafolios).

Portafolio	2011				2014				2017			
	Sub-período 2007-2010				Sub-período 2010-2013				Sub-período 2013-2016			
	Acciones	Alfa	Betas	P-Value	Acciones	Alfa	Betas	P-Value	Acciones	Alfa	Betas	P-Value
P1	CAP	0,0052	1,78	0,0000	VAPORES	-0,0457	2,15	0,0000	MASISA	-0,0053	2,15	0,0000
	VAPORES	-0,0212	1,76	0,0000	BESALCO	0,0108	1,67	0,0000	SQMB	-0,0049	2,11	0,0000
	BESALCO	0,0192	1,60	0,0000	SALFACORP	-0,0118	1,58	0,0000	LTM	-0,0117	2,09	0,0000
	MASISA	-0,0274	1,55	0,0000	SK	0,0116	1,55	0,0000	CAP	-0,0227	2,05	0,0035
P2	SALFACORP	0,0060	1,54	0,0000	LTM	-0,0009	1,50	0,0000	BESALCO	-0,0251	1,89	0,0000
	CENCOSUD	-0,0024	1,50	0,0000	CAP	-0,0086	1,46	0,0000	SALFACORP	-0,0127	1,81	0,0000
	FORUS	0,0038	1,50	0,0000	RIPLEY	-0,0026	1,45	0,0000	VAPORES	-0,0148	1,60	0,0002
	NUEVAPOLAR	-0,0140	1,49	0,0000	FORUS	0,0300	1,41	0,0000	RIPLEY	-0,0013	1,40	0,0000
P3	PARAUCO	0,0039	1,33	0,0000	BCI	0,0125	1,30	0,0000	CENCOSUD	-0,0051	1,34	0,0000
	RIPLEY	-0,0158	1,25	0,0000	CENCOSUD	0,0020	1,20	0,0000	OROBLANCO	-0,0062	1,32	0,0168
	ECL	0,0119	1,17	0,0003	SQMB	-0,0081	1,18	0,0000	ANDINA-B	-0,0030	1,13	0,0003
	CMPC	-0,0055	1,14	0,0000	SECURITY	0,0036	1,18	0,0000	ILC	-0,0004	1,12	0,0000
P4	ENELAM	-0,0066	1,03	0,0000	COPEC	-0,0022	1,18	0,0000	BSANTANDER	0,0030	1,11	0,0000
	SECURITY	-0,0041	1,03	0,0000	CMPC	-0,0097	1,17	0,0000	ITAUCORP	0,0003	1,10	0,0000
	FALABELLA	0,0067	1,02	0,0000	SM-CHILE-B	0,0204	1,11	0,0000	ECL	-0,0004	1,07	0,0000
	CONCHATORO	-0,0079	0,96	0,0000	ANTARCHILE	-0,0062	1,07	0,0000	SONDA	-0,0044	1,01	0,0000
P5	COLBUN	-0,0059	0,95	0,0000	NUEVAPOLAR	-0,0758	1,06	0,1719	BCI	0,0028	1,00	0,0000
	SQMB	0,0169	0,92	0,0037	MASISA	-0,0168	1,06	0,0000	SMSAAM	-0,0015	0,97	0,0000
	ENELGXCH	-0,0058	0,91	0,0000	PARAUCO	0,0100	1,01	0,0000	COPEC	-0,0005	0,94	0,0000
	BCI	0,0034	0,91	0,0000	ITAUCORP	0,0116	1,01	0,0000	SK	-0,0060	0,94	0,0001
P6	ITAUCORP	0,0125	0,89	0,0000	FALABELLA	0,0087	0,96	0,0000	ENELAM	-0,0088	0,93	0,0072
	ANTARCHILE	-0,0069	0,87	0,0000	SONDA	0,0090	0,88	0,0000	CMPC	-0,0045	0,89	0,0000
	COPEC	-0,0044	0,87	0,0000	ENELAM	-0,0082	0,86	0,0000	ANTARCHILE	-0,0016	0,86	0,0000
	LTM	0,0064	0,87	0,0000	ECL	-0,0067	0,85	0,0000	FALABELLA	0,0019	0,84	0,0000
P7	OROBLANCO	0,0161	0,87	0,0072	BSANTANDER	-0,0010	0,83	0,0000	NUEVAPOLAR	-0,0404	0,83	0,2543
	SONDA	0,0000	0,85	0,0000	CONCHATORO	-0,0033	0,78	0,0001	EMBONOR-B	-0,0001	0,74	0,0037
	AESGENER	-0,0036	0,83	0,0000	ANDINA-B	0,0060	0,77	0,0000	ENELGXCH	-0,0115	0,74	0,2448
	SK	0,0089	0,78	0,0008	CHILE	0,0114	0,77	0,0000	FORUS	-0,0035	0,72	0,0372
P8	BSANTANDER	0,0022	0,69	0,0000	EMBONOR-B	0,0107	0,77	0,0005	CCU	-0,0010	0,71	0,0026
	SM-CHILE-B	0,0145	0,69	0,0001	ENELGXCH	-0,0030	0,74	0,0000	ENTEL	-0,0063	0,68	0,0016
	EMBONOR-B	0,0044	0,66	0,0003	AESGENER	0,0039	0,56	0,0003	PARAUCO	0,0057	0,64	0,0004
	CCU	0,0041	0,65	0,0001	CCU	0,0087	0,55	0,0137	COLBUN	0,0000	0,63	0,0011
P9	CHILE	0,0024	0,64	0,0000	COLBUN	-0,0027	0,52	0,0002	CHILE	0,0022	0,62	0,0000
	ANDINA-B	0,0006	0,61	0,0001	OROBLANCO	-0,0258	0,47	0,1397	AESGENER	-0,0051	0,59	0,0126
	AGUAS_A	-0,0044	0,49	0,0001	SMSAAM	-0,0053	0,44	0,0011	SECURITY	0,0040	0,56	0,0057
	ENTEL	-0,0028	0,47	0,0002	IAM	0,0068	0,44	0,0002	CONCHATORO	0,0028	0,51	0,0092
P10	IAM	-0,0011	0,42	0,0007	ILC	-0,0010	0,38	0,0317	SM-CHILE-B	0,0029	0,48	0,0000
	ENELCHILE	-0,0013	0,00	0,0125	ENTEL	-0,0019	0,31	0,0675	IAM	-0,0002	0,45	0,0053
	ILC	-0,0013	0,00	0,0125	AGUAS_A	0,0082	0,30	0,0179	AGUAS_A	-0,0002	0,19	0,2716
	SMSAAM	-0,0013	0,00	0,0125	ENELCHILE	-0,0016	0,00	0,0299	ENELCHILE	-0,0059	0,17	0,1828

Tabla C: Resultados Análisis de Test BJS – FM (20 Portafolios).

Sub-periodo 2007-2012									
Portafolio	Acciones	Alfa	Betas	P-Value	Portafolio	Acciones	Alfa	Betas	P-Value
P1	VAPORES	-0,0435	1,98	0,0000	P11	BCI	0,0042	0,94	0,0000
	CAP	0,0017	1,66	0,0000		SQMB	0,0134	0,92	0,0000
P2	FORUS	0,0134	1,57	0,0000	P12	ENELGXCH	-0,0037	0,87	0,0000
	BESALCO	0,0144	1,57	0,0000		ITAUCCORP	0,0060	0,86	0,0000
P3	SALFACORP	0,0001	1,46	0,0000	P13	SONDA	0,0056	0,81	0,0000
	MASISA	-0,0200	1,39	0,0000		SM-CHILE-B	0,0142	0,81	0,0000
P4	CENCOSUD	-0,0025	1,34	0,0000	P14	COLBUN	-0,0017	0,80	0,0000
	RIPLEY	-0,0132	1,32	0,0000		OROBLANCO	0,0048	0,78	0,0015
P5	NUEVAPOLAR	-0,0431	1,30	0,0073	P15	AESGENER	0,0018	0,78	0,0000
	PARAUCCO	0,0062	1,25	0,0000		BSANTANDER	-0,0005	0,68	0,0000
P6	CMPC	-0,0065	1,22	0,0000	P16	CHILE	0,0047	0,66	0,0000
	SECURITY	-0,0035	1,08	0,0000		EMBONOR-B	0,0082	0,62	0,0000
P7	COPEC	-0,0063	1,07	0,0000	P17	ANDINA-B	0,0047	0,61	0,0000
	ENELAM	-0,0053	1,02	0,0000		CCU	0,0079	0,59	0,0000
P8	LTM	0,0018	1,01	0,0000	P18	AGUAS_A	0,0026	0,43	0,0001
	ANTARCHILE	-0,0084	1,01	0,0000		IAM	0,0030	0,41	0,0000
P9	FALABELLA	0,0055	1,01	0,0000	P19	ENTEL	0,0017	0,37	0,0020
	ECL	0,0099	0,98	0,0000		SMSAAM	-0,0020	0,08	0,1258
P10	CONCHATORO	-0,0061	0,97	0,0000	P20	ILC	0,0019	0,00	0,9163
	SK	0,0079	0,96	0,0000		ENELCHILE	-0,0015	0,00	0,0094

Tabla D: Test de estacionariedad Dickey-Fuller de Precios (Con Drift y Sin Tendencia Determinística).

Acción	Dickey-Fuller	Valor Crítico al 5%	P-Value	Durbin-Watson	Autocorrelación	Hipótesis H0	Conclusión
IPSA	-0,83	-2,88	0,81	1,90	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
AESGENER	-1,88	-2,88	0,34	1,99	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
AGUAS-A	-0,84	-2,88	0,80	2,26	Autocorrelación	No rechaza	No tiene Raíz Unitaria
ANDINA-B	-1,33	-2,88	0,62	2,24	Autocorrelación	No rechaza	No tiene Raíz Unitaria
ANTARCHILE	-1,80	-2,88	0,38	2,17	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
BCI	-0,15	-2,88	0,94	2,11	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
BESALCO	-1,50	-2,88	0,53	1,96	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
BSANTANDER	-0,94	-2,88	0,77	2,27	Autocorrelación	No rechaza	No tiene Raíz Unitaria
CAP	-1,30	-2,88	0,63	1,68	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
CCU	-0,67	-2,88	0,85	1,93	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
CENCOSUD	-1,65	-2,88	0,45	1,99	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
CHILE	0,35	-2,88	0,98	2,27	Autocorrelación	No rechaza	No tiene Raíz Unitaria
CMPC	-1,85	-2,88	0,36	2,08	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
COLBUN	-2,01	-2,88	0,28	2,02	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
CONCHATORO	-3,89	-2,88	0,00	1,97	No hay Evidencia	Rechaza	Tiene Raíz Unitaria
COPEC	-2,10	-2,88	0,25	2,12	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
ECL	-2,14	-2,88	0,23	2,08	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
EMBONOR-B	-0,53	-2,88	0,88	1,90	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
ENELAM	-2,18	-2,88	0,21	2,05	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
ENELCHILE	-0,69	-2,88	0,84	2,02	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
ENELGXCH	-1,84	-2,88	0,36	1,99	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
ENTEL	-1,64	-2,88	0,46	1,90	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
FALABELLA	-1,08	-2,88	0,72	2,11	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
FORUS	-1,17	-2,88	0,68	2,23	Autocorrelación	No rechaza	No tiene Raíz Unitaria
IAM	-0,65	-2,88	0,85	2,08	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
ILC	-0,42	-2,88	0,90	1,92	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
ITAUCORP	-1,71	-2,88	0,42	1,86	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
LTM	-1,36	-2,88	0,60	1,86	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
MASISA	-2,19	-2,88	0,21	1,75	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
NUEVAPOLAR	-1,36	-2,88	0,60	1,62	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
OROBLANCO	-1,48	-2,88	0,54	1,65	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
PARAUCO	0,38	-2,88	0,98	1,83	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
RIPLEY	-1,85	-2,88	0,36	1,84	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
SALFACORP	-1,44	-2,88	0,56	1,73	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
SECURITY	-1,37	-2,88	0,59	1,89	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
SK	-1,14	-2,88	0,70	1,89	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
SM-CHILE B	0,87	-2,88	0,99	1,83	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
SMSAAM	-0,97	-2,88	0,76	2,15	Autocorrelación	No rechaza	No tiene Raíz Unitaria
SONDA	-1,62	-2,88	0,47	1,94	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
SQMB	-1,01	-2,88	0,75	1,87	No hay Evidencia	No rechaza	No tiene Raíz Unitaria
VAPORES	-1,35	-2,88	0,61	1,75	No hay Evidencia	No rechaza	No tiene Raíz Unitaria

Tabla E: Test de estacionariedad Dickey-Fuller de Retornos (Con Drift y Sin Tendencia Determinística).

Acción	Dickey-Fuller	Valor Crítico al 5%	P-Value	Durbin-Watson	Autocorrelación	Hipótesis H0	Conclusión
IPSA	-10,31	-2,88	0,00	1,95	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
AESGENER	-11,79	-2,88	0,00	1,99	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
AGUAS-A	-13,27	-2,88	0,00	2,02	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
ANDINA-B	-13,31	-2,88	0,00	1,99	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
ANTARCHILE	-12,33	-2,88	0,00	1,91	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
BCI	-11,67	-2,88	0,00	1,97	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
BESALCO	-11,21	-2,88	0,00	1,96	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
BSANTANDER	-13,08	-2,88	0,00	1,97	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
CAP	-9,68	-2,88	0,00	2,00	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
CCU	-13,28	-2,88	0,00	1,96	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
CENCOSUD	-10,15	-2,88	0,00	1,98	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
CHILE	-12,15	-2,88	0,00	1,95	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
CMPC	-12,09	-2,88	0,00	1,95	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
COLBUN	-11,63	-2,88	0,00	1,99	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
CONCHATORO	-12,99	-2,88	0,00	1,98	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
COPEC	-12,43	-2,88	0,00	1,96	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
ECL	-11,26	-2,88	0,00	1,98	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
EMBONOR-B	-10,29	-2,88	0,00	1,99	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
ENELAM	-12,07	-2,88	0,00	1,98	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
ENELCHILE	-6,17	-2,89	0,00	1,96	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
ENELGXCH	-15,84	-2,88	0,00	2,05	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
ENTEL	-14,06	-2,88	0,00	1,90	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
FALABELLA	-11,63	-2,88	0,00	1,97	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
FORUS	-11,70	-2,88	0,00	1,97	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
IAM	-12,08	-2,88	0,00	1,96	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
ILC	-11,18	-2,88	0,00	1,92	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
ITAUCORP	-10,30	-2,88	0,00	1,98	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
LTM	-10,52	-2,88	0,00	1,99	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
MASISA	-10,90	-2,88	0,00	1,98	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
NUEVAPOLAR	-9,02	-2,88	0,00	1,97	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
OROBLANCO	-9,35	-2,88	0,00	1,95	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
PARAUCO	-9,10	-2,88	0,00	2,00	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
RIPLEY	-10,66	-2,88	0,00	1,98	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
SALFACORP	-9,76	-2,88	0,00	1,90	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
SECURITY	-10,30	-2,88	0,00	1,96	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
SK	-11,00	-2,88	0,00	1,92	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
SM-CHILE B	-11,95	-2,88	0,00	1,90	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
SMSAAM	-11,84	-2,88	0,00	1,97	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
SONDA	-11,41	-2,88	0,00	1,99	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
SQMB	-11,11	-2,88	0,00	2,00	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria
VAPORES	-10,11	-2,88	0,00	1,99	No hay Evidencia	Rechaza H0	Tiene Raiz Unitaria

Anexo B: Algoritmos de Procesamiento de datos.

```
import investpy
import pandas as pd

## Bajar precios del índice IPSA
data = investpy.indices.get_index_historical_data(index='S&P CLX IPSA',
                                                country='chile',
                                                from_date='01/01/2019',
                                                to_date='30/05/2022',
                                                interval='Weekly')

df = pd.DataFrame(data, columns = ['Date', 'Open', 'High', 'Low', 'Close', 'Volume',
                                  'Currency'])
df.to_excel('C:\Doctorado\Final\Data\IPSA.xlsx', sheet_name='IPSA')

## Bajar precios del índice COLCAP
data = investpy.indices.get_index_historical_data(index='COLCAP',
                                                country='colombia',
                                                from_date='01/01/2019',
                                                to_date='30/05/2022',
                                                interval='Weekly')

df = pd.DataFrame(data, columns = ['Date', 'Open', 'High', 'Low', 'Close', 'Volume',
                                  'Currency'])
df.to_excel('C:\Doctorado\Final\Data\COLCAP.xlsx', sheet_name='COLCAP')

## Bajar precios del índice SP BMV IPC
data = investpy.indices.get_index_historical_data(index='S&P/BMV IPC',
                                                country='mexico',
                                                from_date='01/01/2019',
                                                to_date='30/05/2022',
                                                interval='Weekly')

df = pd.DataFrame(data, columns = ['Date', 'Open', 'High', 'Low', 'Close', 'Volume',
                                  'Currency'])
df.to_excel('C:\Doctorado\Final\Data\COLCAP.xlsx', sheet_name='COLCAP')

## Bajar precios del índice SP BMV IPC
data = investpy.indices.get_index_historical_data(index='S&P/BMV IPC',
                                                country='mexico',
                                                from_date='01/01/2019',
                                                to_date='30/05/2022',
                                                interval='Weekly')

df = pd.DataFrame(data, columns = ['Date', 'Open', 'High', 'Low', 'Close', 'Volume',
                                  'Currency'])
df.to_excel('C:\Doctorado\Final\Data\SP_BMV_IPC.xlsx', sheet_name='SP_BMV_IPC')
```

```

## Bajar precios del índice SP PERU SELECT
data = investpy.indices.get_index_historical_data(index='S&P Peru Select',
                                                country='peru',
                                                from_date='01/01/2019',
                                                to_date='30/05/2022',
                                                interval='Weekly')

df = pd.DataFrame(data, columns = ['Date', 'Open', 'High', 'Low', 'Close', 'Volume',
                                  'Currency'])
df.to_excel('C:\Doctorado\Final\Data\SP_PERU_SELECT.xlsx',
            sheet_name='SP_PERU_SELECT')

```

Tabla B.0.1: Web Scraping para bajar datos de los índices del estudio, Lenguaje Python

```

#Cargar librerias
library(lubridate)
library(tseries)
library(tidyverse)
library(car)
library(foreign)
library(timsac)
library(lmtest)
library(mFilter)
library(nlme)
library(lmtest)
library(broom)
library(kableExtra)
library(knitr)
library(MASS)
library(parallel)
library(mlogit)
library(dplyr)
library(tidyr)
library(forecast)
library(stats)
library(quantmod)
library(foreach)
library(ISLR)
library(caret)
library(glmnet)
library(pacman)
pacman::p_load(pacman,dplyr, ggplot2, rio, gridExtra, scales, ggcorrplot, e1071)

#Paquete GLMNET Regression Lasso

#Sintaxis =glmnet(x,y...,alpha=1,nlambda=100..)
#alpha=0 entonces corre Regresion Ridge---->Contrae coeficientes pero no los hace cero
#alpha=1 entonces corre Regresion Lasso----> hace cero algunos coeficientes
#Este paquete estandariza las variables para que esten en la misma escala

```

```

#Datos que tenemos
attach(train)
names(train)

#Las nuevas observaciones(pronosticar)
attach(test1)
names(test1)

summary(Datos_ChileT)
summary(Datos_ChileTest)

#Para conocer las dimensiones de mis datos
dim(Datos_ChileT)
dim(Datos_ChileTest)

#Para generar las variables predictoras
x=model.matrix(ripsa~.,Datos_ChileT)
print(x)

#Para quitar el intercepto
x=model.matrix(ripsa~.,Datos_ChileT)[-1]
print(x)

#Para generar la variable dependiente
y=data.matrix(Datos_ChileT[,c('ripsa','deuda', 'credito', 'religion', 'cancer',
    'perdida', 'dinero', 'vender', 'default', 'agua', 'riesgo',
    'petroleo', 'economia', 'venta_corta', 'codicia', 'alimento',
    'mineral', 'salud', 'burbuja', 'politica', 'energia', 'conflicto',
    'divisas', 'medio_ambiente', 'austeridad', 'impuestos',
    'tasa_de_interes', 'crisis', 'precio_del_oro', 'desempleo', 'pobreza',
    'inflacion', 'precio_del_cobre', 'guerra', 'Covid', 'riesgo_pais',
    'paro', 'caida_de_la_bolsa', 'recesion', 'estallido_social', 'pensiones',
    'AFP', 'sequia', 'drogas', 'narcotrafico', 'delincuencia', 'arriendo',
    'acciones', 'restaurante', 'portafolio', 'alojamiento', 'ingresos',
    'mercados', 'retorno', 'crecimiento', 'cobertura', 'casamiento',
    'bonos','derivados', 'ganancia', 'playa', 'bienes', 'bolsa de Valores',
    'bancario', 'feliz', 'automovil', 'finanzas', 'invertir', 'casa',
    'metales', 'viaje', 'crecimiento_economico', 'ganar', 'vacaciones',
    'riqueza', 'exito', 'estilo_de_vida', 'mercados_financieros',
    'pelicula', 'arte', 'cultura', 'comprar', 'turismo', 'consumir',
    'libertad', 'cocina', 'mano_de_obra', 'diversion', 'consumo',
    'PIB', 'dividendos', 'beneficios', 'inversion', 'emprendimiento',
    'IPSA')])
print(y)

lasso.model=glmnet(x,y,alpha =1)
dim(coef(lasso.model))

Coeflasso=coef(lasso.model)
print(Coeflasso)
lasso.model$lambda

```

```

plot(lasso.model,"lambda",label=TRUE)

#Para saber el lambda modelo 60
lasso.model$lambda[60]
log(lasso.model$lambda[60])
coef60=coef(lasso.model)[,60]
print(coef60)
plot(lasso.model,"lambda",label=TRUE)
abline(v=log(lasso.model$lambda[60]), col="blue",lwd= 4,lty =3)

lasso.model$lambda[55]
log(lasso.model$lambda[55])
coef(lasso.model)[,55]
plot(lasso.model,"lambda",label= TRUE)
abline(v=log(lasso.model$lambda[55]), col="blue",lwd= 4,lty =3)

#hacer prediccion con un modelo en particular
x.test1=model.matrix(price_range~.,test1)[-1]
pred=predict(lasso.model, s=lasso.model$lambda[45],newx = x.test1)
print(pred)

#Mejor lambda con validación cruzada
sal.cv=cv.glmnet(x,y,alpha=1)
plot(sal.cv)
mejor.lambda =sal.cv$lambda.min
mejor.lambda
log(mejor.lambda)

##hacer predicción con mejor lambda
coef(lasso.model)[,which(lasso.model$lambda==mejor.lambda)]
pred=predict(lasso.model, s=mejor.lambda,newx = x.test1)
pred

#Root Mean Square Error --Error de predicción del modelo
data.frame(RMSE=RMSE(pred,test1$price_range),Rsquare = R2(pred,test1$price_range))

```

Tabla B.0.2: Programa en Lenguaje R para procesar términos por medio de Regresión LASSO

```

from pytrends.request import TrendReq

## Se crea la conexion, se indica que el lenguaje es español de Chile
pytrend = TrendReq(hl='es-CL')

## Se construye el payload a enviar
pytrend.build_payload(kw_list=["Covid"], cat=0, timeframe='today 1-m', geo='CL', gprop='')

## Envía el payload para obtener la serie temporal e imprime la información
print(pytrend.interest_over_time())

```

Tabla B.0.3: Algoritmo para extraer datos de Google Trends.