



**UNIVERSIDAD AUTÓNOMA DEL  
ESTADO DE MÉXICO**



---

---

**FACULTAD DE ECONOMÍA**

**“ESTRATEGIAS DE COBERTURA CON FUTUROS SOBRE EL ÍNDICE  
BURSÁTIL DE LA BOLSA MEXICANA DE VALORES: EVIDENCIA DE  
UN MODELO DE REGRESIÓN CUANTÍLICA”**

**TESIS**

**QUE PARA OBTENER EL TÍTULO DE:**

**LICENCIADO EN ACTUARÍA**

**PRESENTA:**

**FIDEL MARTINEZ HUITRON**

**ASESOR:**

**DR. EN ING. RAÚL DE JESÚS GUTIÉRREZ**

**REVISORES**

**DRA. EN E. LIDIA E. CARVAJAL GUTIÉRREZ**

**DR. EN E. ÓSCAR M. RODRÍGUEZ PICHARDO**

**TOLUCA, ESTADO DE MÉXICO**

**FEBRERO 2024**

## Índice

Índice de tablas .....	3
Índice de figuras .....	4
Introducción .....	5
Capítulo 1. La cultura de la administración de riesgos .....	9
1.1 El riesgo en los mercados financieros.....	9
1.2 La función de la administración de riesgos.....	13
1.3 Los productos derivados en la cobertura de riesgos .....	15
Capítulo 2. Marco teórico .....	25
Capítulo 3. Metodología .....	38
3.1 Descripción de los datos.....	38
3.3 Modelo de regresión cuantílica.....	42
3.4 Criterios de evaluación de la efectividad de la cobertura .....	47
3.4.1 Índice de eficiencia de reducción de varianza.....	47
3.4.2 Valor en riesgo.....	48
Capítulo 4. Evidencia para la Bolsa Mexicana de Valores .....	51
4.1 Estadísticas descriptivas.....	51
4.2 Estimación de las razones de cobertura dentro de la muestra .....	54
4.3 Estimación de las razones de cobertura fuera de la muestra .....	60
4.4 Evaluación de la efectividad de la cobertura dentro de la muestra .....	67
4.5 Análisis de la efectividad de la cobertura fuera de la muestra .....	71
Capítulo 5. Conclusiones.....	80
Bibliografía .....	82

## Índice de tablas

Tabla 1.1. Comportamiento del mercado de futuros del MexDer en el periodo 2013-2022. .....	21
Tabla 4.1. Estadísticas básicas de los rendimientos de los precios al contado y futuros. .....	52
Tabla 4.2. Estimaciones del término constante de ambas regresiones dentro de la muestra.....	55
Tabla 4.3. Resultados de la estimación de las RCMV para los 3 horizontes de cobertura. .....	56
Tabla 4.4. Resultados de las estimaciones diarias de las RCMV fuera de la muestra. .	64
Tabla 4.5. Resultados de las estimaciones semanales de las RCMV fuera de la muestra. .....	65
Tabla 4.6. Resultados de las estimaciones mensuales de las RCMV fuera de la muestra. .....	66
Tabla 4.7. Resultados del índice eficiente de reducción de varianza para los diferentes cuantiles.....	69
Tabla 4.8. Resultados del índice eficiente del VaR para los diferentes cuantiles. ....	70

## Índice de figuras

Figura 1.1. Principales mercados de productos derivados por volumen de contratos 2019. .....	20
Figura 2.1. Diagrama de dispersión entre los rendimientos de los precios al contado y de futuros. ....	28
Figura 3.1. Comportamiento de los precios spot del índice S&P/BMV IPC 2013- 2022. ....	40
Figura 3.2. Comportamiento de los precios de los futuros sobre el índice S&P/BMV IPC. .....	41
Figura 4.1. Rendimientos diarios de los precios spot y futuros del índice S&P/BMV IPC. ....	53
Figura 4. 2. RCMV cuantílicas y MCO para los tres horizontes de cobertura. ....	58
Figura 4.3. Gráfico de dispersión y líneas de tendencia de la regresión cuantílica para los diferentes cuantiles. ....	60
Figura 4.4. Estimación de las RCMV diarias cuantílicas y por el modelo de MCO. ....	61
Figura 4.5. Estimación de las RCMV semanales cuantílicas y por el modelo de MCO. ....	62
Figura 4.6. Estimación de las RCMV mensuales cuantílicas y por el modelo de MCO. ....	62
Figura 4.7. Índices eficientes de cobertura diarios fuera de la muestra de MCO y regresión cuantílica. ....	72
Figura 4.8. Índices eficientes de cobertura fuera de la muestra semanales con MCO y regresión cuantílica. ....	74
Figura 4.9. Índices eficientes de cobertura mensuales fuera de la muestra con MCO y regresión cuantílica. ....	75
Figura 4.10. Índices diarios de reducción del VaR fuera de la muestra. ....	77
Figura 4.11. Índices semanales de reducción del VaR fuera de la muestra. ....	77
Figura 4.12. Índices mensuales de reducción del VaR fuera de la muestra. ....	78

## **Introducción\***

En las últimas décadas, los mercados accionarios han experimentado importantes cambios, transformaciones e innovaciones como consecuencia de una serie de factores, tales como el desempeño económico global, la regulación financiera, los avances tecnológicos y computacionales, integración financiera y eventos de carácter sistémico como las crisis financieras y la crisis sanitaria de COVID-19. En este sentido, el desarrollo de los mercados accionarios trae consigo mayor incertidumbre y volatilidad, y con ello una mayor exposición al riesgo que afecta a los participantes en los mercados accionarios. Por ello, el riesgo financiero es uno de los temas que más preocupa a empresas, gobiernos e inversionistas institucionales e individuales a tal grado que su administración se ha convertido en uno de los desafíos y prioridades más importantes, debido a que se manifiesta de diversas formas y niveles en los mercados financieros, particularmente en las economías de países emergentes.

Por lo que la creciente volatilidad en los mercados accionarios ha obligado a los inversionistas institucionales e individuales a buscar mejores mecanismos de cobertura para contrarrestar los efectos negativos de la exposición al riesgo de precios en las inversiones de portafolio. Asimismo, la integración financiera ha propiciado un mayor efecto contagio entre los mercados financieros, lo que ha reducido los beneficios de la diversificación internacional en las inversiones de portafolio. En consecuencia, los mercados de futuros no solo juegan un papel importante en la fijación de precios<sup>1</sup>, sino también en la cobertura de la exposición al riesgo en diferentes escenarios de volatilidad normal y extrema (Zurita, 2002).

De esta manera, las estrategias de cobertura con contratos de futuros financieros permiten a los inversionistas, institucionales e individuales, reducir el riesgo de fluctuación en los precios de los activos subyacentes a bajos costos de transacción. Además, los contratos de futuros se negocian en mercados organizados regulados y altamente líquidos. Por su

---

\* Esta tesis es producto del proyecto de investigación "La percepción de seguridad y derechos humanos en los migrantes mexicanos en Canadá participantes en el PTAT", SIEA, UAEM; clave 6633/2022SF.

<sup>1</sup> Los mercados de futuros desempeñan un papel crucial en la fijación de precios al permitir a los participantes anticipar y gestionar los riesgos asociados con la volatilidad en los precios de los activos subyacentes. Además, los participantes del mercado contribuyen a la eficiencia y transparencia en la valoración de los activos subyacentes a través de la formación de precios en los contratos de futuros. (Bodie et al., 2019).

parte, las operaciones con futuros están altamente apalancadas y libres de riesgo de incumplimiento debido a que cuentan con una cámara de compensación, la cual se encarga de que las transacciones con futuros se lleven a cabo de manera eficiente y sana para el desarrollo de los mercados (Johnson, 1960).

Sin embargo, uno de los problemas de la cobertura es determinar el número de contratos de futuros requeridos para reducir el riesgo sistémico en los portafolios de inversión. En este contexto, la estrategia de cobertura *naïve* consiste básicamente en tomar la misma cantidad de futuros por unidad del activo subyacente para neutralizar la exposición al riesgo de precios. Esta estrategia proporciona resultados óptimos para reducir la varianza de los rendimientos del portafolio de cobertura cuando la correlación entre los cambios de los precios de contado y futuros es perfecta, y la base es igual a cero. Sin embargo, estas condiciones no se cumplen en la práctica debido a la falta de sincronización entre los mercados y la presencia de costos de transacción (de Jesús et al., 2021).

En este contexto de la administración del riesgo, la literatura ha propuesto diferentes modelos de cobertura para la determinación de las razones de cobertura de mínima varianza (RCMV). Ederington (1979) propone el modelo de mínimos cuadrados ordinarios (MCO) para estimar las RCMV. Este modelo de cobertura convencional estima la RCMV a través de la pendiente del modelo MCO. El modelo MCO es usado comúnmente debido a su fácil implementación, puesto que la estimación de la RCMV depende de la relación entre los cambios en los precios al contado y los cambios en los precios de los futuros (Lien et al., 2015).

Desafortunadamente, diversos estudios han comprobado que el coeficiente de la pendiente del modelo MCO puede subestimar las RCMV y reducir la efectividad de la cobertura debido a que este modelo no captura el problema de la correlación serial observado en las series financieras. Además, otra de las debilidades del modelo MCO es que la estrategia de cobertura es constante a través del tiempo. Este hecho es inconsistente en la práctica, debido a que el comportamiento de los precios en los mercados financieros tiende a fluctuar a través del tiempo como consecuencia de los desequilibrios entre la oferta y demanda o eventos de carácter económico y financiero (Myers y Thompson, 1989). Sin embargo, el problema de la correlación serial se puede

relajar utilizando el modelo de vectores autorregresivos (VAR). En este sentido, los modelos VAR estiman las RCMV al afectar los rendimientos de los precios de contado y futuros con los valores actuales y los valores rezagados propios de cada variable (Spencer et al., 2018).

No obstante, Chou et al. (1996) argumentan que la estructura VAR tiene problemas para estimar las razones de cobertura óptima porque no considera la relación de equilibrio de largo plazo entre variables financieras no estacionarias e integradas de orden uno, también conocida como relación de cointegración. Por su parte, Ghosh (1993) y Lien y Luo (1994) argumentan que, si existe una relación de cointegración entre los precios spot y futuros, esta relación se debe incorporar en el modelo VAR para mejorar la efectividad de la cobertura. En consecuencia, el modelo de vectores de corrección de error (VEC) recoge la relación de equilibrio a largo plazo para estimar las RCMV, pero su estimación es aún constante a través del tiempo.

De esta manera diversos estudios han propuesto el uso de los modelos de heteroscedasticidad condicional autorregresiva generalizada bivariados (MGARCH, por sus siglas en inglés) para estimar las razones de cobertura dinámicas (Myers, 1991; Park y Switzer (1995a, 1995b), Lypny y Powalla (1998), Koutmos y Pericli (1998), Lien y Tse, 1999; Floros y Vougas, 2004; Cotter y Hanly, 2006). Estos modelos de cobertura estiman apropiadamente las RCMV utilizando las varianzas y covarianzas condicionales de los rendimientos de los precios de contado y futuros. Sin embargo, Lai (2018) señala que las coberturas dinámicas se estiman a través de la distribución de innovaciones condicionales bajo un supuesto de normalidad. Por lo que los momentos de orden mayor no son tomados en cuenta en la estimación de las RCMV, esto es, los diferentes niveles de asimetría. Por ejemplo, la mayoría de los modelos GARCH bivariados proporcionan el mismo peso a los choques positivos y negativos. Por otra parte, los modelos de cobertura dinámicos no capturan totalmente el efecto de los eventos extremos generados por las crisis financieras, lo cual puede sesgar la estimación de las RCMV y reducir la efectividad de la cobertura.

El objetivo de esta tesis es aplicar el modelo de regresión por cuantiles para estimar las razones de cobertura óptima para mejorar la efectividad de la cobertura que coadyuve a reducir la varianza del portafolio de cobertura para diferentes cuantiles de la distribución

condicional de los rendimientos del índice accionario S&P/BVM IPC utilizando futuros financieros. En este marco, Lien et al. (2015) argumentan que el modelo de regresión por cuantiles mejora las estrategias de coberturas debido a que la aproximación recoge apropiadamente los efectos asimétricos, las colas anchas de la distribución condicional y la heterocedasticidad observada en las series de los rendimientos financieros. En este trabajo se plantea la siguiente pregunta de investigación: ¿El modelo de regresión por cuantiles puede mejorar las estrategias de la cobertura de los inversionistas institucionales e individuales que participan en la Bolsa Mexicana de Valores?

Asimismo, en el trabajo se pretende validar la siguiente hipótesis de investigación: El modelo de regresión cuantílica estima razones de cobertura que proporcionan suficiente información para reducir la exposición al riesgo de precios de los inversionistas institucionales e individuales.

Esta tesis está organizada de la siguiente manera: En el capítulo 1 se describe el panorama general del riesgo en los mercados financieros y sus implicaciones en la toma de decisiones de inversión. Así como la importancia de los productos derivados en la administración y cobertura de riesgos financieros. El capítulo 2 describe brevemente al método MCO como una alternativa tradicional para la estimación de las RCMV. El capítulo 3 propone al modelo de regresión cuantílica como una herramienta para estimar las RCMV, describe los datos y los métodos para la evaluación de la eficiencia de la cobertura. El capítulo 4 presenta y discute los resultados de la evidencia empírica de los métodos MCO y regresión cuantílica, así como la evaluación de su eficiencia. Finalmente, el capítulo 5 contiene las conclusiones de la tesis y futuras líneas de investigación.



## **Capítulo 1. La cultura de la administración de riesgos**

### **1.1 El riesgo en los mercados financieros**

En el panorama financiero actual, los mercados financieros han sido el epicentro de la actividad económica global debido a que su desempeño es fundamental para la asignación de capital, la formación de precios y el diseño de portafolios de inversiones a nivel internacional para los participantes. Esto se atribuye en gran medida a la amplia gama de activos financieros, tales como acciones, bonos, materias primas e instrumentos financieros de cobertura. Los mercados financieros ofrecen oportunidades para que inversionistas individuales e institucionales aumenten sus activos y aseguren sus flujos financieros, además de canalizar el capital hacia empresas y proyectos que impulsan la innovación, la expansión y la creación de empleo.

En la actualidad, los mercados financieros se caracterizan por ser altamente líquidos y volátiles debido a la creciente incertidumbre generada por choques de mercado. En este contexto, la volatilidad es una característica inherente de mercados financieros debido a las variaciones de precios que pueden ir desde pequeñas fluctuaciones hasta cambios bruscos. La volatilidad se deriva como resultado de diferentes factores internos y externos tales como eventos económicos o políticos, noticias inesperadas o modificaciones en las percepciones de los inversionistas. Estos factores son los principales detonantes del alto grado de incertidumbre en los mercados financieros debido a su capacidad para modificar las expectativas de los participantes del mercado, creando un entorno en el que las decisiones de inversión se vuelven más difíciles de anticipar y evaluar (Hull, 2018).

Por otra parte, la volatilidad y la incertidumbre en los mercados financieros no necesariamente tienen un impacto negativo para los inversionistas a pesar de ser factores aparentemente desafiantes. La volatilidad puede ofrecer intervalos temporales para comprar activos subvalorados o vender aquellos que están sobrevalorados. Asimismo, la incertidumbre puede fomentar la diversificación de carteras y promover el uso de estrategias más sólidas en la administración del riesgo. Sin embargo, un hecho importante de resaltar es que los inversionistas deben evaluar minuciosamente los riesgos financieros y los premios al desarrollar eficientes estrategias de inversión, esto es, los inversionistas deben estar dispuestos a adaptarse rápidamente a cambios en el mercado y tomar decisiones informadas (Roll y Ross, 1980).

De manera similar, la globalización, digitalización e interconexión de los mercados han generado un entorno más riesgoso debido a que la información fluye rápidamente y las decisiones de inversión se ejecutan en cuestión de segundos. Esta velocidad sin precedentes ha provocado un aumento tanto en la frecuencia como en la magnitud de los movimientos en los mercados financieros. No obstante, a pesar de que la globalización tiene sus beneficios evidentes como el acceso a oportunidades de inversiones internacionales, también la globalización puede conllevar a un riesgo más severo cuando una crisis o evento adverso puede propagarse velozmente entre distintos países. Esta interconexión global dificulta la administración del riesgo, debido a que las crisis financieras pueden ser más prolongadas y sus efectos más devastadores para los participantes en los mercados financieros (Mishkin y Eakins, 2020).

En este sentido, los inversionistas institucionales e individuales deben estar preparados para enfrentar una variedad de riesgos, tanto sistemáticos como inesperados. Los riesgos sistemáticos, como las desaceleraciones económicas, las crisis financieras y las fluctuaciones en las tasas de interés, pueden afectar al mercado completo o a segmentos importantes del mismo. Los inversionistas deben estar preparados para reconsiderar sus estrategias e incluso realizar cambios en sus inversiones para minimizar los impactos negativos de estos riesgos. Por otra parte, los riesgos inesperados, como problemas geopolíticos súbitos, catástrofes naturales o una eventual pandemia, pueden provocar un significativo efecto adverso en los mercados financieros. Es fundamental estar alerta ante estos sucesos y tomar medidas para mitigar sus riesgos (Hagigi y Sivakumar, 2009).

Los efectos de la crisis financiera global de 2007-2008 y la pandemia de COVID-19 en los mercados financieros internacionales fueron muy severos a nivel global. Estos acontecimientos marcaron un hito importante no solo en el ámbito social, sino también en economía financiera al desencadenar una creciente incertidumbre y aversión al riesgo entre los inversionistas, lo que provocó caídas significativas en las principales bolsas de valores del mundo. A pesar de surgir bajo diferentes contextos e impulsados por factores heterogéneos, ambas crisis comparten características comunes importantes. En este tenor, la crisis financiera global es un ejemplo clásico de cómo los eventos globales pueden desencadenar recesiones económicas y turbulencia en los mercados financieros. Esta crisis originada en el sector inmobiliario de EE. UU., como consecuencia del estallido

de la burbuja de las hipotecas subprime, tuvo un fuerte impacto a nivel global. Los bancos colapsaron a tal grado de llegar a la quiebra, mientras que los mercados financieros se desplomaron y millones de empleos se perdieron. Los inversionistas se encontraron con activos tóxicos y una profunda desconfianza en los mercados financieros. En consecuencia, la crisis financiera global marcó la línea de la importancia de no concentrar demasiado capital en un solo tipo de activo o sector. Por lo que la diversificación en diferentes clases de activos financieros como bonos, acciones y materias primas ayudó a reducir el impacto en las carteras de inversión.

Otro evento más reciente es la pandemia de COVID-19, la cual comenzó en diciembre de 2019 y tuvo un efecto global inmediato en los mercados financieros. Los índices bursátiles experimentaron caídas abruptas, las empresas se vieron obligadas a cerrar y la economía global entró en recesión. La creciente incertidumbre y las implicaciones económicas de la pandemia generó volatilidad sin precedentes en los mercados financieros internacionales. Como consecuencia, la pandemia resaltó la importancia de la liquidez y la preparación para eventos inesperados. Los inversionistas con reservas de efectivo o activos líquidos estaban mejor posicionados para aprovechar las oportunidades de compra cuando los mercados se desplomaron. Además, la crisis sanitaria resaltó la importancia de la administración de riesgos a través de instrumentos como los seguros y las opciones (Banco Mundial, 2022).

A raíz de eventos devastadores, los inversionistas han comenzado a adoptar estrategias más sofisticadas para reducir los efectos negativos de las crisis financieras. En este contexto, la evaluación de riesgos se ha vuelto más profunda y sofisticada. Asimismo, los inversionistas están utilizando modelos más avanzados para identificar y comprender los riesgos en sus inversiones de portafolio, esto es, el análisis cuidadoso de la diversificación de activos financieros, la correlación entre ellos y su comportamiento en diferentes escenarios a fin de entender mejor el perfil de riesgo de las inversiones, y de esta manera contrarrestar sus efectos negativos.

En este sentido, la diversificación inteligente de portafolio es más importante que la diversificación simple, ya que los inversionistas buscan activos que se comporten de forma distinta en diferentes condiciones del mercado, a diferencia de simplemente invertir en una

variedad de activos sin considerar su correlación. De igual forma, una estrategia común entre los inversionistas es diseñar portafolios de activos financieros altamente líquidos, debido a que proporciona a los inversionistas la flexibilidad de aprovechar oportunidades cuando los mercados financieros se desplomen. Adicionalmente, las reservas de efectivo apoyan como soporte en momentos de incertidumbre y alta volatilidad, al permitir a los inversionistas evitar pérdidas por la venta anticipada de activos financieros cuando requieren liquidez. Por otra parte, la regulación financiera es otro aspecto importante por considerar, debido a que desempeña un papel esencial en la protección de los inversionistas y desarrollo de los mercados financieros, así como en la promoción de la estabilidad financiera (Bekaert y Wu, 2000).

Aunado a lo anterior, la cobertura con instrumentos financieros como opciones y futuros financieros se ha vuelto más común como una forma de protegerse contra caídas extremas del mercado. Estos instrumentos financieros de cobertura actúan como seguros, lo que significa que los inversionistas pueden comprarlos para limitar sus pérdidas en caso de que los mercados financieros se vuelvan más volátiles o caigan bruscamente. De esta manera, las estrategias de cobertura pueden proporcionar tranquilidad en momentos de incertidumbre, a pesar de tener costos asociados (Hagigi y Sivakumar, 2009).

En el entorno financiero altamente volátil, los contratos de futuros financieros pueden ayudar a administrar adecuadamente el riesgo a tal grado de convertirse en un pilar fundamental para proteger las inversiones y garantizar la estabilidad financiera. Este hecho refleja la necesidad apremiante de que inversionistas individuales e institucionales reconozcan la importancia de implementar estrategias efectivas de administración de riesgos en sus portafolios de inversión. En un entorno donde los eventos económicos, financieros, políticos y tecnológicos pueden generar impactos significativos en las inversiones de portafolio, la cultura de la administración del riesgo proporciona herramientas sólidas para identificar, medir y mitigar la exposición al riesgo de los participantes en los mercados financieros.

## **1.2 La función de la administración de riesgos**

Tradicionalmente, el riesgo ha sido ampliamente considerado como un factor negativo en el contexto financiero, puesto que se le asocia principalmente con la posibilidad de pérdida o la ocurrencia de eventos desfavorables que pueden tener un impacto adverso en el desempeño financiero de las instituciones financieras, empresas y gobiernos. En las últimas décadas, el riesgo financiero se ha convertido en una preocupación primordial para diversos agentes económicos, que incluyen a instituciones financieras, empresas e inversionistas individuales e institucionales. El riesgo está presente en cualquier actividad económica y se ha convertido en el foco central de las transacciones bursátiles. Por lo que el riesgo se manifiesta de diferentes formas y niveles en los mercados financieros, particularmente en las economías emergentes.

De acuerdo con Hagigi y Sivakumar (2009), el riesgo se puede traducir como sinónimo de volatilidad, puesto que representa variabilidad en los rendimientos de los financieros, lo que incrementa la aversión al riesgo que afecta la conducta psicológica de los inversionistas para asignar capital en los mercados financieros en periodos de turbulencia financiera. En las últimas décadas, los participantes en los mercados financieros han experimentado creciente volatilidad debido a una serie de factores y eventos tales como la globalización de los mercados, la integración financiera, así como los avances tecnológicos y de telecomunicaciones que han acelerado las transacciones financieras y fomentado la cultura de la información. Asimismo, las crisis financieras son otro de los factores importantes que han sacudido los cimientos del sistema financiero global e incrementado la regulación financiera para un sano desarrollo de los mercados financieros. Finalmente, eventos geopolíticos también han contribuido a la inestabilidad financiera y económica global, lo que ha generado no solo incertidumbre entre los inversionistas, sino también severas pérdidas para los administradores de portafolio.

Sin embargo, es importante destacar que entender las dimensiones del riesgo en el contexto de la economía global y el entorno financiero internacional tiene sus ventajas, puesto que puede ofrecer oportunidades para lograr un buen desempeño financiero de parte de las empresas al reducir sus costos de capital y mantener una sana reputación de

las instituciones financieras. En este contexto, la función de la administración de riesgos juega un papel importante en la asignación eficiente de capital en los mercados financieros altamente volátiles, porque una evaluación de las alternativas de inversión de acuerdo con las condiciones prevalentes de mercado y el nivel de tolerancia de riesgo asumido por los administradores de portafolio puede mejorar el desempeño financiero de los agentes económicos.

Derivado de lo anterior, la administración de riesgos cobra mayor importancia en los mercados financieros, porque se puede definir como el proceso que permite identificar, medir y controlar la exposición al riesgo financiero en diversos escenarios. Asimismo, la administración del riesgo desempeña un papel clave en el proceso de la toma de decisiones de inversión en portafolios, porque permite implementar modelos de medición y cobertura más sofisticados para reducir el impacto de la exposición al riesgo de precios de los participantes en los mercados financieros, particularmente en las economías emergentes (Fernández, 2022). Además, la adopción de la administración de riesgos como una disciplina permite a las instituciones financieras, empresas e inversionistas tomar decisiones de mercado más riesgosas, pero más redituables al interactuar en una amplia gama de mercados. De acuerdo con la relación riesgo-rendimiento, las inversiones más riesgosas suelen proporcionar un rendimiento más elevado siempre y cuando la estrategia de inversión esté bien evaluada o controlada a través de una efectiva administración del riesgo (McCarthy y Flynn, 2004).

En periodos de extrema volatilidad, los participantes en los mercados financieros no solo deben seleccionar alternativas de inversión óptimas, sino también desarrollar estrategias efectivas de cobertura que ayuden a reducir el riesgo en los portafolios de inversión. De esta manera, una de las alternativas más viables en la cobertura del riesgo financiero es que las instituciones financieras, empresas, gobiernos e inversionistas institucionales participen directamente en los mercados de productos derivados. Estos instrumentos financieros de cobertura proporcionan protección parcial a los inversionistas institucionales en periodos de calma y extrema volatilidad con costos de transacción relativamente bajos. Dentro de esta variedad de instrumentos financieros de cobertura se

encuentran los contratos de opciones financieras, contratos adelantados, permutas financieras o swaps y los contratos de futuros financieros, los cuales ayudan a los inversionistas a adoptar posiciones estratégicas de cobertura con el fin de enfrentar las oscilaciones del mercado (Fong et al., 2005). De esta manera, Ríos (2014) argumenta que las instituciones financieras, empresas e inversionistas institucionales han incrementado significativamente su participación en transacciones financieras con productos derivados en todo el mundo, principalmente en los países industrializados.

### **1.3 Los productos derivados en la cobertura de riesgos**

En las últimas décadas, el riesgo ha evolucionado en los mercados financieros a tal grado que su control se ha convertido en todo un desafío para las instituciones financieras, empresas e inversionistas institucionales. En este contexto, los mercados de productos derivados han sido importantes mecanismos de cobertura para la administración del riesgo de los participantes en los mercados financieros, particularmente en los mercados de capitales. Los mercados de productos derivados han crecido y desarrollado rápidamente desde la década de 1990, especialmente en las economías emergentes que han eliminado los controles de capital e implementado programas de privatización en sectores estratégicos como respuesta al proceso de globalización. En la década de 1980 y principios de la década de 1990, los mercados de productos derivados iniciaron operaciones en los países de Hong Kong, Japón, Brasil, México y Europa occidental. Sin embargo, los contratos de futuros y otros productos derivados comenzaron a negociarse hasta la segunda mitad de la década de 1990 (Lien y Mei, 2008).

Los mercados de productos derivados se han vuelto atractivos para los participantes en los mercados financieros debido a que presentan una serie de características operativas y estructurales que los distinguen de los mercados al contado. Estas particularidades brindan ventajas operativas notables, como la reducción de los costos de transacción, una mayor liquidez y la facilidad para llevar a cabo ventas en corto (Chance y Brooks, 2000). Asimismo, los mercados de productos derivados listan instrumentos financieros de cobertura con fechas de vencimiento, requerimientos de margen, límites de precios y procedimientos de división de órdenes.

En este contexto, los productos derivados financieros han sido creados para proporcionar protección a las instituciones financieras, empresas e inversionistas institucionales ante cambios inesperados en los precios de los activos subyacentes. De esta manera, Hammoudeh y McAleer (2013) destacan que la cobertura contra diversos tipos de riesgos es la razón principal del uso de productos derivados. Al adoptar una posición en los mercados de futuros opuesta a la que se mantiene en el mercado al contado, un coberturista puede potencialmente compensar las pérdidas en la posición descubierta. La naturaleza organizada, estandarizada y centralizada de las bolsas de futuros significa que los formadores de mercado o especuladores asumen los riesgos que los coberturistas desean transferir.

Asimismo, los derivados financieros son instrumentos financieros cruciales en la formación de precios. Su capacidad para mantener la eficiencia de los mercados, al reducir los costos de transacción, es una de las características distintivas que los define. Sin embargo, los derivados financieros tales como los futuros y opciones ofrecen un mecanismo más eficiente para la compra y venta de activos financieros en comparación con las transacciones en el mercado al contado. En consecuencia, la eficiencia de los mercados de futuros y opciones atrae a un gran número de inversionistas y especuladores, lo que genera una mayor liquidez y, a menudo, fomenta un flujo sustancial de información de precios hacia los mercados.

El proceso de formación de precios en los mercados de futuros es un pilar fundamental para determinar el valor de los activos subyacentes. Por ello, los productos derivados proporcionan información adicional para la toma de decisiones de inversión. De esta manera, cuando los contratos de futuros sobre índices accionarios son introducidos en un mercado de productos derivados, representan una fuente invaluable de información para los administradores de riesgos e inversionistas. Los precios de los futuros tienen la capacidad para revelar señales sobre la demanda prevista de los activos subyacentes, lo cual influye de manera directa en las decisiones relacionadas con la inversión.



Otra función importante de los contratos de futuros es la fijación de precios. En este sentido, los estudios sobre la función de la fijación de precios en los mercados de futuros a menudo se enfocan en la relación entre las variaciones de precios en el mercado al contado y los futuros. En los mercados altamente desarrollados, como Estados Unidos, los futuros sobre índices accionarios frecuentemente lideran las cifras reportadas en los índices subyacentes, con estimaciones del tiempo de liderazgo que oscilan entre cinco y cuarenta y cinco minutos. Por otro lado, esta relación en los mercados emergentes puede adquirir matices más complejos, con los contratos de futuros liderando o siguiendo al mercado al contado en distintos momentos. No obstante, vale la pena resaltar que esta relación no es unidireccional, puesto que frecuentemente se observa una relación bidireccional, lo que muestra que tanto el mercado al contado como el mercado de futuros contienen información valiosa acerca de las oscilaciones de precios en el otro mercado. Este hecho refleja la interconexión inherente de ambos mercados y cómo mutuamente se influyen (Lien y Mei, 2008).

Asimismo, los contratos de futuros financieros desempeñan una función esencial al ofrecer a los inversionistas la capacidad de administrar y mitigar los riesgos asociados con las economías emergentes y en vías de desarrollo. Este hecho cobra especial importancia para los inversionistas internacionales que desean invertir en instrumentos financieros de los mercados emergentes, ya que estos suelen caracterizarse por su mayor volatilidad y, por consiguiente, su mayor nivel de riesgo. El uso de productos derivados proporciona a los inversionistas una sólida protección contra la incertidumbre en variables financieras cruciales, tales como los tipos de cambio, las tasas de interés o los precios de los activos financieros. Por lo que la cobertura con derivados financieros proporciona mayor certidumbre para llevar a cabo inversiones seguras en economías emergentes y en vías de desarrollo.

Por otro lado, los derivados financieros son importantes para estabilizar los precios en los mercados financieros. En este sentido, los mercados de futuros garantizan un proceso más eficiente para la protección contra pérdidas de precios, puesto que el uso de los contratos de futuros que es un mecanismo natural para estabilizar los precios al contado.

Por lo tanto, surge la hipótesis planteada de que los mercados de futuros reducen la volatilidad de los precios al contado. En este contexto, diversos argumentos teóricos se han presentado para explicar por qué y cómo la existencia de mercados de futuros podría afectar la volatilidad de los mercados de los activos subyacentes. Si el mercado no es perfectamente competitivo, la introducción de futuros puede inducir a los grandes productores a manipular los precios al contado mediante decisiones de producción y almacenamiento, aumentando la volatilidad de los precios spot (Mayhew 2000).

La evolución de los derivados financieros a lo largo del tiempo ha sido notable y ha respondido a las cambiantes necesidades financieras y la creciente complejidad de los mercados financieros. En un mundo cada vez más interconectado, estos instrumentos financieros de cobertura han madurado y desarrollado para abordar una amplia variedad de riesgos y estrategias de inversión. Sin embargo, es esencial subrayar que, debido a su compleja naturaleza, el uso de productos derivados demanda un conocimiento profundo y una comprensión exhaustiva de sus implicaciones, ya que pueden presentar riesgos considerables si se manejan incorrectamente (Hammoudeh y McAleer, 2013).

En este contexto, es importante reconocer que el empleo de derivados financieros conlleva implicaciones significativas para los sistemas financieros. Por un lado, estos instrumentos financieros de cobertura pueden contribuir a la estabilidad financiera al permitir que los inversionistas administren y reduzcan de manera efectiva los riesgos financieros. Sin embargo, el uso imprudente de los productos derivados o si los inversionistas se enfrentan a eventos inesperados, pueden agravar el riesgo sistémico, dando lugar a dinámicas de crisis más complejas y difíciles de anticipar.

De esta manera, uno de los retos fundamentales relacionados con los productos derivados radica en la capacidad para actuar oportunamente ante un canal de transmisión del contagio financiero. Cuando una crisis económica o financiera afecta a un mercado o país, las posiciones con productos derivados pueden verse afectadas, lo que a su vez puede propagar la crisis a otros mercados y regiones del mundo. El fenómeno del contagio financiero se hizo notorio durante la crisis financiera global de 2008, donde los derivados

financieros, en particular, aquellos vinculados a hipotecas de alto riesgo, desempeñaron un papel significativo en la expansión de la crisis a todo el mundo (Atilgan et al., 2016). Los estudios centrados en las crisis ocurridas en los mercados desarrollados y emergentes han revelado que los derivados financieros pueden desempeñar roles tanto positivos como negativos. Por un lado, estos instrumentos financieros de cobertura pueden contribuir a que países y empresas administren con mayor eficiencia los riesgos, lo que a su vez puede atraer inversiones extranjeras y fomentar el desarrollo económico. Por otro lado, si se utilizan de manera especulativa o sin una comprensión adecuada de los riesgos involucrados, los derivados financieros pueden generar alta volatilidad y la posibilidad de crisis financieras.

No obstante, los contratos de futuros ofrecen a los coberturistas la oportunidad de compensar las posibles pérdidas generadas en el mercado de contado, al tomar una posición opuesta en el mercado de futuros. Esta estrategia de cobertura se beneficia de la naturaleza organizada y estandarizada de las bolsas de futuros, donde los especuladores o formadores de mercado asumen los riesgos. Aunque los mercados de futuros han demostrado ser útiles para proteger a los inversionistas contra la incertidumbre en torno a los precios de los activos subyacentes y la volatilidad de los mercados, los contratos de futuros no pueden eliminar totalmente la exposición al riesgo de precios (Gordon y Rausser 1984).

Sin embargo, este entorno financiero riesgoso se ha convertido en un desafío y una prioridad para los reguladores de las economías de mercados emergentes que buscan establecer medidas prudentes y conservadoras para fomentar el sano desarrollo de los mercados financieros. Dichas regulaciones deberían crear incentivos para que los participantes en los mercados financieros utilicen los productos derivados de manera adecuada a fin de facilitar los flujos de capital sin incrementar el riesgo en las inversiones reales y de portafolio. De acuerdo con Dodd (2000), la regulación apropiada incluye la actualización de las reglas contables, los requisitos de capital y el nivel de tolerancia de riesgo para las instituciones financieras a través de la presentación de informes más transparente sobre las transacciones financieras, tanto para los instrumentos financieros

listados en bolsas organizadas como en los mercados extrabursátiles o *over the counter* (OTC, por sus siglas en inglés).

En consecuencia, los mercados de futuros de materias primas se han expandido y desarrollado principalmente en los países de economías desarrolladas. Aunque la implementación y uso de contratos de futuros de productos básicos ha adquirido cada vez más importancia en las economías de mercados emergentes en los últimos años como una posible solución a los problemas de volatilidad de precios e ingresos que enfrentan los productores de productos básicos. En la Figura 1.1 se presenta la clasificación por número de contratos negociados de los principales mercados de productos derivados a nivel global para el año de 2019. La figura muestra que algunos mercados de productos derivados de economías emergentes se encuentran entre las bolsas más importantes del mundo en términos del número de contratos negociados.

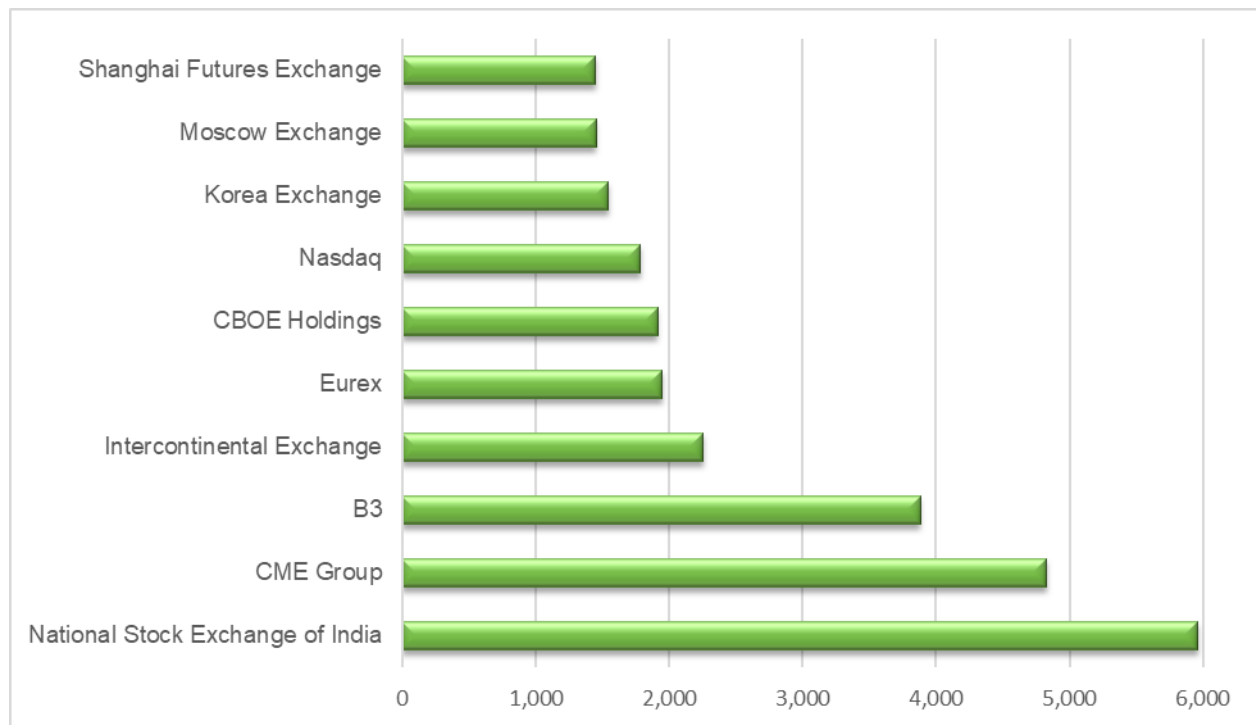


Figura 1.1. Principales mercados de productos derivados por volumen de contratos 2019.  
Fuente: Futures Industry Association, Statista 2021.

En este marco, la Bolsa Nacional de Valores de la India (NSE, por sus siglas en inglés) se situaba en primer lugar a nivel mundial en lo referente al intercambio de productos derivados financieros con un volumen de contratos de compra y venta de 5,960.65

millones en el año de 2019. De esta manera, la NSE es una de las principales bolsas de valores de la India y una de las más grandes del mundo en términos de volumen de operaciones. Por su parte, la Bolsa Nacional de derivados de la India se caracteriza por la operación de contratos de futuros y opciones sobre el índice accionario NIFTY 50. La bolsa cuenta con tecnología avanzada para facilitar el acceso a la negociación y liquidación de contratos de productos derivados, así como sistemas electrónicos que permiten la ejecución rápida y eficiente de las operaciones.

Tabla 1.1. Comportamiento del mercado de futuros del MexDer en el periodo 2013-2022.

AÑO	Operaciones	Volumen	Importe	Interés abierto
2022	160,928	9,604,496	2,015,567,193,853	1,634,194
2021	150,994	7,546,762	1,609,320,741,919	819,062
2020	197,752	6,610,987	1,497,684,908,485	491,875
2019	243,776	6,377,583	1,423,380,181,796	594,781
2018	321,066	7,841,451	1,727,953,289,407	470,041
2017	300,468	10,613,400	2,171,850,207,007	1,027,798
2016	342,817	12,528,580	2,417,521,312,132	1,513,043
2015	299,129	16,548,629	2,528,400,939,083	1,948,769
2014	242,150	29,227,298	3,917,243,184,980	
2013	188,972	26,575,225	3,349,040,535,839	

Fuente: elaboración propia con información del MexDer.

En segundo lugar, se encuentra la Bolsa Mercantil de Chicago (CME, por sus siglas en inglés) con un volumen de operación de 4,830.04 millones de contratos de productos derivados negociados en 2019. La CME se encuentra en Chicago, Illinois y es una de las bolsas de productos derivados más grandes del mundo, conocida por su amplia gama de productos financieros. Esta bolsa tiene gran influencia en los mercados globales.

Finalmente, La Bolsa B3 de Brasil, también conocida como la Bolsa de Comercio y Futuros de Brasil (BM&FBovespa) es la tercera bolsa de productos derivados con una operación de 3,880.62 millones de contratos negociados en el mismo año. La BM&FBovespa es la principal bolsa de valores y mercado de derivados de Brasil, y su implementación ha sido clave en los mercados financieros de América Latina.

Sin embargo, a pesar del impresionante crecimiento de los mercados de productos derivados en todo el mundo, existe una considerable heterogeneidad en el grado de desarrollo entre las bolsas de productos derivados de los países desarrollados con respecto a los países emergentes. En México, el Mercado Mexicano de Derivados (MexDer) desempeña un papel fundamental en el sistema financiero nacional. No obstante, el crecimiento y desarrollo del MexDer en el contexto global revelan ciertas distinciones clave en términos de tamaño, diversidad, participación internacional, regulación y desarrollo tecnológico como se muestra en la Tabla 1.1. En este sentido, la evolución del mercado de futuros y opciones en México ha sido importante para la economía del país en el periodo de 2013 a 2022, puesto que la información de diez años proporciona una visión de la actividad y evolución de los mercados de futuros financieros en México y sus tendencias a lo largo del tiempo. Aunque el número de operaciones, volumen y montos de los contratos de futuros realizadas en el MexDer ha variado notablemente a lo largo del periodo de estudio 2013-2022. En el periodo de 2013 a 2016, los rublos de operación e importe han mantenido una tendencia alcista, aunque con una disminución en el importe al alcanzar el monto de 2,417,521 millones de pesos a pesar de haber registrado 342,817 operaciones.

No obstante, el número de operaciones, volumen e importe han disminuido dramáticamente en el periodo 2017-2020, particularmente en el año de 2019 cuando registró un importe de 1,423,380 millones de pesos mexicanos con un volumen de 6,377,583. Mientras que el volumen e importe cambia de tendencia notablemente a pesar de que el número de operaciones alcanzó un nivel de 150,994 transacciones con contratos de futuros en año de 2021. Otro hecho importante de resaltar es que el mayor volumen de operación es alcanzado en el 2014 con un nivel máximo de 29,227,298 contratos de

futuros negociados, lo que implica un año de actividad intensa en el mercado de futuros de México. Sin embargo, estas fluctuaciones sugieren cambios en la actividad y el interés de los inversionistas por el uso de contratos de futuros durante estos años. Por lo que estos cambios de tendencia pueden reflejar variaciones en la valoración de los activos subyacentes y la percepción del mercado. Por último, el análisis del interés abierto muestra una tendencia mixta para el periodo 2015-2022. Este importante indicador representa el número total de contratos de futuros que permanecen activos y que no han sido cancelados por los formadores de mercado o especuladores. El comportamiento del interés abierto es creciente en el periodo 2015-2017 y el año de 2022. Mientras que la tendencia del interés abierto disminuye notablemente en el periodo 2018-2020, lo que obedece a que en este periodo de estudio hubo una mayor cancelación de contratos de futuros por parte de los formadores de mercado. Esta estrategia de operación beneficia a los especuladores. Este hecho ocurre en la práctica cuando las expectativas sobre el activo subyacente no se cumplen en el futuro. Por lo que la cámara de compensación del MexDer se tiene que hacer cargo del riesgo de los coberturistas hasta el vencimiento del futuro o hasta la fecha de liquidación del contrato de futuros.

De esta manera, el MexDer es un mercado de productos derivados en desarrollo, pero que ha experimentado un crecimiento significativo en los últimos años. Si bien su estructura financiera aún no puede considerarse grande o diverso como otros mercados de productos derivados más desarrollados. Sin embargo, su función juega un papel importante para el sistema financiero mexicano y la economía del país, puesto que proporciona oportunidades de inversión y cobertura a los participantes en los mercados financieros tanto nacionales como extranjeros. Asimismo, el MexDer es un mecanismo importante para la eficiente administración de riesgos y asignación de capital en los mercados de capitales, dinero y cambiarios porque permiten a los inversionistas reducir los efectos negativos de la volatilidad en periodos de turbulencia financiera. Por esta razón, no es sorprendente el crecimiento importante del mercado de derivados en México en los últimos años. Hoy en día, los productos derivados han ido más allá de los instrumentos financieros de cobertura más negociados y utilizados para administrar la exposición al riesgo de los diferentes activos subyacentes tales como tasas de interés,

divisas, materias primas, acciones y bonos, y evitar crisis financieras que contagien a otros sistemas financieros o economías a nivel global (Raturi, 2005).



## Capítulo 2. Marco teórico

### 2.1. Estrategias de cobertura con futuros

Los mercados de futuros juegan un papel importante en la cobertura del riesgo de precios, así como en la fijación de los precios. De acuerdo con Hull (2003), en la implementación de coberturas con futuros es necesario calcular la razón de cobertura óptima, la cual permite determinar el número de contratos de futuros para reducir la exposición al riesgo de la posición abierta en el mercado de contado. Los inversionistas institucionales e investigadores han empleado dos estrategias de cobertura: la cobertura tradicional uno a uno y la cobertura de mínima varianza o razón de cobertura óptima. La estrategia de cobertura uno a uno requiere una unidad de una posición de futuros para reducir la exposición al riesgo de una unidad del activo subyacente. De esta manera, la estrategia tradicional *naïve* es muy simple de implementar en la práctica financiera, puesto que asume que un contrato de futuros es suficiente para controlar el riesgo de precios.

Sin embargo, la cobertura uno a uno es efectiva para reducir el riesgo en los portafolios de inversión cuando los cambios en los precios de los futuros coinciden exactamente con los cambios en los precios de contado y el riesgo base es nulo, lo cual es imposible en la práctica por la falta de sincronización en ambos mercados y la presencia de costos de transacción. De hecho, Peters (1986) ha demostrado que la fijación de precios erróneos tiende a incrementar la volatilidad en el mercado de futuros en un 20% aproximadamente. Para relajar el problema de la correlación imperfecta, diversos estudios han propuesto utilizar la razón de cobertura de mínima varianza (Johnson, 1960; Stein, 1961; Ederington, 1979). En este contexto, la razón de cobertura de mínima varianza (RCMV) se obtiene al minimizar la varianza de los rendimientos del portafolio de cobertura.

De esta manera, el rendimiento del portafolio de cobertura para una posición larga o corta se puede definir de la siguiente manera:

$$R_{C_t} = \Delta S_t - \beta \Delta F_t \quad (1)$$

$$R_{C_t} = -\Delta S_t + \beta \Delta F_t \quad (2)$$

donde  $\beta$  representa la razón de cobertura o número de futuros requeridos para cubrir la posición de contado abierta,  $\ln(S_t)$  y  $\ln(F_t)$  representan el logaritmo de los precios al contado y de futuros en el tiempo  $t$ . En consecuencia, los rendimientos de los precios al contado y de futuros se pueden definir como  $\Delta S_t = \ln(S_t) - \ln(S_{t-1})$  y  $\Delta F_t = \ln(F_t) - \ln(F_{t-1})$ , respectivamente.

La RCMV se obtiene al minimizar la varianza del portafolio de cobertura, la cual se puede expresar de la siguiente manera:

$$\text{VAR}(R_{C_t}) = \text{VAR}(\Delta S_t) - 2\beta \text{COV}(\Delta S_t, \Delta F_t) + \beta^2 \text{VAR}(\Delta F_t) \quad (3)$$

donde  $\text{VAR}(\Delta S_t)$ ,  $\text{VAR}(\Delta F_t)$ , y  $\text{COV}(\Delta S_t, \Delta F_t)$  denotan las varianzas y covarianzas de los rendimientos de los precios de contado y de futuros, respectivamente.

Una vez definida la varianza de los rendimientos del portafolio de cobertura se deriva con respecto a  $\beta$  para obtener la RCMV de la siguiente manera:

$$\frac{\partial \text{VAR}(R_{C_t})}{\partial \beta} = -2 \text{COV}(\Delta S_t, \Delta F_t) + 2\beta \text{VAR}(\Delta F_t).$$

Ahora la derivada de la varianza del portafolio de cobertura es igualada a cero para obtener la RCMV, es decir,

$$-2 \text{COV}(\Delta S_t, \Delta F_t) + 2\beta \text{VAR}(\Delta F_t) = 0$$

$$2 \text{COV}(\Delta S_t, \Delta F_t) = 2\beta \text{VAR}(\Delta F_t).$$

Por lo tanto, la razón de cobertura de mínima varianza se determina al despejar  $\beta$ , es decir,

$$\beta^* = \frac{\text{COV}(\Delta S_t, \Delta F_t)}{\text{VAR}(\Delta F_t)} \quad (4).$$

De esta manera, la razón de cobertura de mínima varianza es la proporción de la covarianza entre los rendimientos de los precios de contado y de futuros y la varianza de los rendimientos de la posición de futuros. Generalmente, la RCMV es menor a la unidad porque minimiza el riesgo ante la presencia del riesgo base<sup>2</sup> (De Jesús, 2016).

Sin embargo, numerosos estudios han propuesto diversas técnicas para la estimación empírica de la RCMV para diferentes activos financieros. La razón de cobertura óptima se puede obtener a través del coeficiente de la pendiente de la regresión lineal entre los rendimientos de los precios de contado y los rendimientos de los precios de los futuros, siempre y cuando los precios al contado y de futuros no estén cointegrados y la matriz de varianza-covarianza condicional sea invariable en el tiempo. Con ello, la ecuación de la regresión se puede representar de la siguiente manera:

$$\Delta S_t = \alpha + \beta^* \Delta F_t + \varepsilon_t \quad (5).$$

## 2.2 Modelo de regresión de mínimos cuadrados

De acuerdo con Hanke y Wichern (2006), el objetivo del modelo de regresión es tratar de explicar la relación que existe entre la variable dependiente  $Y$  (variable respuesta) y un conjunto de variables independientes (variables explicativas)  $X_1, \dots, X_n$ . Por su parte, el modelo de regresión lineal simple trata de explicar la relación que existe entre la variable respuesta  $Y$  y la única variable explicativa  $X$ . Para fines de esta tesis, la variable dependiente  $Y = \Delta S$  y la variable independiente  $X = \Delta F$ . En otras palabras,  $\Delta S_t$  depende de  $\Delta F_t$ , en donde  $\Delta S_t$  y  $\Delta F_t$  son los rendimientos de los precios al contado y de futuros en el tiempo  $t$ . En este tenor, el primer paso para observar si un modelo de regresión lineal tiene sentido, es graficar un diagrama de dispersión. En la Figura 2.1 se puede observar que tiene sentido estimar una regresión simple debido al hecho de que el comportamiento dinámico de los rendimientos de los precios al contado y de los precios de los futuros.

---

<sup>2</sup> El riesgo base se deriva de la variabilidad de la diferencia entre el precio del futuro y el precio del activo subyacente. En términos generales, este tipo de riesgo está asociado a factores macroeconómicos, condiciones generales del mercado y eventos que afectan globalmente a todas las inversiones.




Figura 2.1. Diagrama de dispersión entre los rendimientos de los precios al contado y de futuros.  
Fuente: Elaboración propia con datos de Bloomberg en Python.

En consecuencia, el modelo de regresión lineal tiene la siguiente expresión:

$$\Delta S = \alpha + \beta \Delta F + \varepsilon_t \quad (6)$$

donde  $\alpha$  es la ordenada en el origen (el valor que toma  $\Delta S$  cuando  $\Delta F$  vale 0).  $\beta$  es la pendiente de la recta e indica cómo cambia  $\Delta S$  al incrementar  $\Delta F$  en una unidad, que para fines de este trabajo es la RCMV. Además,  $\varepsilon$  representa los errores o residuales de la estimación del modelo, y es una variable que incluye un conjunto grande de factores. Cada uno de factores influye en la respuesta sólo en pequeña magnitud.  $\Delta S$  y  $\Delta F$  son variables aleatorias, por lo que no se puede establecer una relación lineal exacta entre ellas (Carollo, 2012).

Para la estimación del modelo de regresión lineal simple (MCO), es importante expresar la ecuación (5) como una ecuación de la recta de la siguiente forma:

$$\widehat{\Delta S} = \hat{\alpha} + \hat{\beta} \Delta F = a + b \Delta F \quad (7)$$

De tal manera que la ecuación de la recta se ajuste a la nube de puntos. Para ello, el método MCO es utilizado, el cual consiste en minimizar la suma de los cuadrados de los errores o residuales de la siguiente manera:

$$\sum_{t=1}^T (\hat{\varepsilon}_t)^2 = \sum_{t=1}^T (\Delta S_t - \Delta \hat{S}_t)^2 \quad (8)$$

La suma de los cuadrados de las diferencias entre los valores reales observados ( $\Delta S_t$ ) y los valores estimados ( $\Delta \hat{S}_t$ ).

Con la estimación del modelo lineal usando el método de MCO se obtienen las siguientes expresiones para los coeficientes  $a$  y  $b$ :

$$a = \overline{\Delta S} - b \overline{\Delta F}, \quad b = \frac{S_{\Delta S \Delta F}}{S_{\Delta F}^2},$$

donde  $\overline{\Delta S}$  y  $\overline{\Delta F}$  denotan las medias muestrales de  $\Delta S$  y  $\Delta F$ , respectivamente.  $S_{\Delta F_t}^2$  es la varianza muestral de  $\Delta F_t$  y  $S_{\Delta F_t, \Delta S_t}$  es la covarianza muestral entre  $\Delta F_t$  y  $\Delta S_t$ .

Estas medidas de tendencia se calculan de la siguiente manera:

$$\overline{\Delta F} = \frac{1}{T} \sum_{t=1}^T \Delta F_t, \quad (9)$$

$$\overline{\Delta S} = \frac{\sum_{t=1}^T \Delta S_t}{T}, \quad (10)$$

$$S_{\Delta F_t}^2 = \frac{\sum_{t=1}^T (\Delta F_t - \overline{\Delta F})^2}{T}, \quad (11)$$

$$S_{\Delta S_t}^2 = \frac{\sum_{t=1}^T (\Delta S_t - \overline{\Delta S})^2}{T}, \quad (12)$$

$$S_{\Delta F_t, \Delta S_t} = \frac{\sum_{t=1}^T (\Delta F_t - \overline{\Delta F})(\Delta S_t - \overline{\Delta S})}{T}. \quad (13)$$

El valor de  $b$  se define como el coeficiente de regresión de  $\Delta S$  sobre  $\Delta F$ , el cual se denota como  $b_{\Delta S/\Delta F}$ .

Asimismo, la recta de regresión de  $\Delta F$  sobre  $\Delta S$  se calcula al aproximar  $\Delta F$  por  $\widehat{\Delta F}$  de la siguiente manera:

$$\widehat{\Delta F} = a + b \Delta S, \quad (14)$$

donde

$$a = \overline{\Delta F} - b \overline{\Delta S}, \quad b = \frac{S_{\Delta F \Delta S}}{S_{\Delta S}^2},$$

Sin embargo, es totalmente incorrecto despejar  $\Delta F$  de la ecuación  $\widehat{\Delta S} = a + b \Delta F$  para calcular la recta de regresión de  $\Delta F$  sobre  $\Delta S$ . Además, es importante observar que la recta de regresión pasa siempre por el centro de gravedad de la nube de puntos, es decir, por el punto  $(\overline{\Delta F}, \overline{\Delta S})$ .

De acuerdo con Carollo (2012), el coeficiente de regresión proporciona información sobre el comportamiento de la variable  $\Delta S$  frente a la variable  $\Delta F$  de manera que

- a) Si  $b_{\Delta S/\Delta F} = 0$ , para cualquier valor de  $\Delta F$  la variable  $\Delta S$  es constante (es decir, no cambia a través del tiempo).
- b) Si  $b_{\Delta S/\Delta F} > 0$ , indica que al aumentar el valor de  $\Delta F$ , también aumenta el valor de  $\Delta S$ .
- c) Si  $b_{\Delta S/\Delta F} < 0$ , indica que al aumentar el valor de  $\Delta F$ , el valor de  $\Delta S$  disminuye.

Por otra parte, el coeficiente de correlación lineal ( $r$ ) entre  $\Delta F$  y  $\Delta S$  trata de medir la dependencia lineal que existe entre las dos variables. En este sentido, el coeficiente de correlación se denota con  $r$  y se calcula de la siguiente manera:

$$r = \frac{S_{\Delta F \Delta S}}{S_{\Delta F} S_{\Delta S}}, \quad (15)$$

Esta herramienta proporciona información valiosa sobre la fuerza y dirección de la relación entre las variables dependiente e independiente. La fuerza de la correlación se evalúa en función de la proximidad de  $r$  a 1 o -1. Cuando  $r$  se acerca a 1, señala una correlación positiva perfecta, indicando que las dos variables están relacionadas de manera positiva y que cuando una variable aumenta, la otra también lo hace de manera lineal. Por otro lado, cuando  $r$  se acerca a -1, la correlación es negativa perfecta. Este hecho sugiere que las dos variables están relacionadas de manera negativa, de modo que cuando una variable aumenta, la otra disminuye de manera lineal. Si  $r$  se acerca a 0, esto indica que no existe una correlación lineal significativa entre las dos variables (Geraghty, 2023).

En este sentido, el coeficiente de correlación asume una relación lineal entre las variables que se están analizando. Esto significa que se enfoca en identificar patrones de cambio lineal en los datos, lo cual puede no ser adecuado si la relación entre las variables es no lineal. En los casos de que la relación sea curvilínea o compleja, el coeficiente de correlación podría no reflejar adecuadamente la verdadera naturaleza de la relación. Otra consideración importante es que la correlación puede revelar una relación estadística, pero no necesariamente muestra causalidad, es decir, el hecho de que dos variables estén correlacionadas no implica que una causa a la otra (Hanke y Wichern, 2006).

Ahora bien, el coeficiente de determinación  $R^2$  es la relación entre la variación explicada y la variación total. El coeficiente de determinación mide o interpreta la cantidad relativa de la variación que ha sido explicada por la recta de regresión, es decir, la proporción de cambio en  $\Delta S$  explicado por un cambio en la variable  $\Delta F$ . De esta manera, su valor siempre estará entre 0 y 1. Por lo que su valor en expresa en términos porcentuales, lo que implica

que un valor de 1 es preferible a un valor de 0. La fórmula para calcular el coeficiente de determinación es la siguiente:

$$R^2 = \frac{\sum(\widehat{\Delta S}_t - \overline{\Delta S})^2}{\sum(\Delta S_t - \overline{\Delta S})^2}, \quad (16)$$

donde  $\sum(\Delta S_t - \overline{\Delta S})^2$  es la suma total de cuadrados (STC) y  $\sum(\widehat{\Delta S}_t - \overline{\Delta S})^2$  es la suma explicada de cuadrados (SEC).

Una vez que se ha ajustado el modelo de regresión por mínimos cuadrados, y se han obtenido los coeficientes, es fundamental evaluar si estos coeficientes son estadísticamente significativos. En la regresión lineal, se ajusta un modelo que incluye coeficientes para cada variable independiente. En este caso, la hipótesis nula ( $H_0$ ) es que el coeficiente correspondiente a una variable independiente es estadísticamente igual a cero, lo que significa que no tiene un efecto significativo en la variable dependiente. Por su parte, la hipótesis alternativa ( $H_1$ ) es que el coeficiente es estadísticamente mayor a cero, lo que indica que la variable independiente tiene un efecto significativo. Para realizar esta prueba, se calcula un estadístico t-Student para cada coeficiente. El estadístico t se compara con un valor crítico basado en el nivel de significancia deseado. Si el estadístico t es significativamente diferente del valor crítico, se rechaza la hipótesis nula y se concluye que la variable independiente tiene un efecto significativo en la variable dependiente (Carollo, 2012).

En el análisis de regresión, además de evaluar la significancia de los coeficientes individuales, resulta esencial llevar a cabo una prueba global para determinar si, en conjunto, al menos uno de los coeficientes es significativamente diferente de cero. Esta evaluación se realiza mediante la Prueba F, donde la hipótesis nula ( $H_0$ ) plantea que todos los coeficientes de regresión son iguales a cero, lo que implicaría que el modelo de regresión en su conjunto carece de significancia. Por el contrario, la hipótesis alternativa ( $H_1$ ) sugiere que al menos uno de los coeficientes no es igual a cero, lo que indica que el modelo tiene relevancia en la explicación de la relación entre las variables. De esta manera, el estadístico F se obtiene como el cociente entre el SCE y SCR. Si el valor de F



resulta ser significativamente mayor que el valor crítico correspondiente, se procede a rechazar la hipótesis nula, lo que conduce a la conclusión de que, al menos, una de las variables independientes ejerce un efecto estadísticamente significativo sobre la variable dependiente.

Hasta el momento se ha explicado a grandes rasgos como aproximar el modelo de regresión lineal  $\Delta S = \alpha + \beta \Delta F + \varepsilon_t$  mediante la recta  $\widehat{\Delta S} = a + b \Delta F$ . Sin embargo, para garantizar que esta aproximación sea válida, algunas condiciones estadísticas se deben cumplir. En primera instancia, el supuesto de independencia se debe cumplir entre los errores, esto es, que no exista autocorrelación entre valores sucesivos de los residuos en el modelo de regresión. En este tenor, la prueba de Durbin-Watson es comúnmente utilizada para detectar el problema de la autocorrelación. El estadístico de Durbin-Watson detecta la presencia de correlación de primer orden, es decir, si los errores en un periodo dado están relacionados con los errores en el periodo inmediato anterior (Hanke y Wichern, 2006). Este fenómeno puede proporcionar estimaciones sesgadas de las razones de cobertura óptima.

En segunda instancia, otra importante prueba de diagnóstico es la prueba para detectar si la varianza de los errores es heteroscedástica, la cual evalúa si la varianza de los errores de regresión es cambiante en el tiempo en todos los niveles de las variables independientes. Sin embargo, la hipótesis nula denota que la varianza es constante a través del tiempo (homoscedasticidad), mientras que la hipótesis alternativa sugiere que la varianza no es constante (heteroscedasticidad). El fenómeno de la heteroscedasticidad puede ser un problema en el análisis de regresión porque puede llevar a estimaciones ineficientes de los coeficientes y sesgar los resultados de las pruebas estadísticas. De esta manera, en la literatura existen dos pruebas estadísticas que pueden coadyuvar a evaluar la presencia de heteroscedasticidad en los errores o residuales, las cuales son la prueba de Breusch-Pagan y la prueba de White, entre otras.

Por otra parte, la prueba de normalidad se enfoca en determinar si los errores del modelo de regresión siguen una distribución normal. La hipótesis nula de esta prueba establece

que los errores se distribuyen normalmente, lo que significa que se asemejan a una curva de campana típica. La hipótesis alternativa sugiere que los errores no siguen una distribución normal. A su vez, la normalidad de los errores se evalúa con diversas pruebas de bondad de ajuste, como la prueba de Kolmogórov-Smirnov o la prueba de Shapiro-Wilk. Estas pruebas comparan la distribución de los errores con una distribución normal teórica. Si los resultados de la prueba indican que los errores no se ajustan a una distribución normal, podría ser necesario reconsiderar la validez de las conclusiones basadas en el modelo de regresión (Carollo, 2012).

Por su parte, el método de regresión de mínimos cuadrados ordinarios (MCO) ha sido empleado en diversos estudios para la cobertura del riesgo con contratos de futuros (Ederington, 1979; Hill y Schneeweis, 1981; Benninga et al., 1983; Figlewski, 1985; Witt et al., 1987; Myers y Thompson, 1989; Castellino, 1990; Myers, 1991). Por ejemplo, Figlewski (1984) fue el primero en analizar el desempeño de la cobertura del modelo MCO utilizando futuros sobre el índice accionario Standard and Poor's 500 (S&P 500). Los resultados confirman que el método MCO presenta el mejor desempeño para estimar las RCMV y mejora la efectividad de la cobertura a diferencia del modelo de cobertura beta. Asimismo, Junkus y Lee (1985) examinan la eficiencia de la cobertura para tres bolsas de futuros de índices bursátiles en Estados Unidos. La evidencia empírica revela que el desempeño del modelo MCO es superior al desempeño de los modelos de cobertura beta y uno a uno para reducir el riesgo de precios en los portafolios de inversión de los diferentes índices accionarios.

Sin embargo, el enfoque basado en el modelo MCO ha recibido severas críticas para el diseño óptimo de estrategias de cobertura. En este marco, Park y Bera (1987) concluyen que el modelo MCO es inapropiado porque el fenómeno de la heteroscedasticidad observada en las series financieras no es tomado en cuenta en la estimación de las razones de cobertura óptima. Por su parte, Bell y Krasker (1986) argumentan que el modelo MCO solo proporciona razones de cobertura incondicionales, lo cual no es válido cuando el cambio esperado en los precios de los futuros depende de un conjunto de información disponible. Por otra parte, Herbst et al. (1989) confirman que la estimación de

la RCMV basada en el modelo MCO puede ser sesgada debido a la presencia de correlación serial. Para relajar este problema, el modelo de vectores autorregresivos (VAR, por sus siglas en inglés) es propuesto para estimar las RCMV con futuros financieros y mejorar la efectividad de la cobertura. Sin embargo, la literatura ha documentado que el modelo VAR tiene error de especificación cuando los precios de dos series financieras están cointegradas, lo que puede conducir a estimaciones sesgadas de las razones de cobertura óptima (Engle y Granger, 1987). En consecuencia, Ghosh (1993) estudia la efectividad de la cobertura utilizando contratos de futuros sobre el índice accionario S&P 500 y encuentra evidencia de que el modelo MCO subestima las razones de cobertura para los portafolios de inversión debido a que la relación de cointegración es omitida.

Por su parte, Lien y Luo (1993) recogen el efecto de cointegración a través de un modelo GARCH y estiman RCMV para diferentes horizontes de cobertura. Los hallazgos confirman que la relación de cointegración juega un papel importante en la eficiencia de la cobertura del riesgo contratos de futuros sobre divisas duras. Asimismo, Lien (1996) incorpora el termino de corrección de error en la estructura VAR y demuestra que las coberturas del modelo de vectores autorregresivos con corrección de error (VEC, por sus siglas en inglés) proporciona mejores coberturas para reducir el riesgo de precios. Chou et al. (1996) confirman el desempeño superior del modelo VEC con respecto al del modelo MCO para la estimación de las RCMV en los mercados accionarios y futuros del índice bursátil Nikkei 225 de Japón.

No obstante, Holmes (1996) analiza el desempeño de los modelos GARCH bivariado, VEC y MCO para la cobertura con contratos de futuros del índice bursátil de referencia de la Bolsa de Valores de Londres FTSE 100. Los resultados muestran que el modelo MCO estima mejores RCMV que los modelos VEC y GARCH bivariado. Asimismo, Lien y Tse (1999) hacen una extensión al modelo VEC para estimar las RCMV y mejorar la efectividad de la cobertura. El estudio utiliza datos diarios del índice accionario Nikkei 225 y sus futuros para el período 1989-1996. Los resultados revelan que el modelo MCO presenta el peor desempeño en comparación con los modelos VAR, VEC y GARCH bivariados para los horizontes de cobertura mayores a 5 días.

En este contexto, Yang (2001) estima las RCMV y estudia la efectividad de la cobertura con cuatro modelos de cobertura constante y dinámica utilizando datos del índice accionario y futuros de los mercados de Australia. Los resultados muestran que el modelo VEC proporciona mejores estimaciones de las RCMV a diferencia de los modelos MCO, VAR y GARCH bivariado. Por su parte, Lien et al. (2002) utilizan datos de los mercados al contado y de futuros sobre divisas, materias primas e índices bursátiles para evaluar el desempeño del modelo GARCH bivariado y sus variantes. Los resultados muestran que no hay evidencia suficiente que avale el desempeño superior de los modelos de cobertura dinámica sobre el modelo MCO en la estimación de las RCMV. Además, la evidencia empírica confirma que el modelo GARCH bivariado con correlaciones constantes no se debe considerar para las decisiones de cobertura debido a sus altos costos de transacción por el concepto del rebalanceo del portafolio de cobertura.

En un estudio más reciente, Lee y Chien (2010) examinan el desempeño de los modelos GARCH y MCO utilizando contratos de futuros de los mercados accionarios y futuros de Taiwán para estimar las RCMV y evaluar la efectividad de la cobertura. La evidencia empírica muestra que el modelo MCO condicional con liquidez de mercado supera a los modelos GARCH bivariados y MCO tradicional. Por su parte, Yao y Wu (2012) comparan el desempeño de los modelos VAR, VEC y MCO utilizando contratos de futuros de los índices accionarios Shanghai y Shenzhen de China. Los hallazgos confirman que las RCMV del método MCO son más efectivas para reducir la varianza del portafolio de cobertura dentro y fuera de la muestra. De manera similar, Kaur y Gupta (2019) estudian la efectividad de la cobertura con contratos de futuros sobre el índice accionario NIFTY 50 de la India. De acuerdo con el criterio de reducción de varianza, los resultados evidencian que las RCMV del modelo convencional mejoran la efectividad de la cobertura. Asimismo, Hasan et al. (2020) estiman las RCMV utilizando los precios de los futuros del índice accionario KOSPI 200 empleando 8 diferentes modelos econométricos. Los resultados demuestran que el modelo MCO exhibe mejor desempeño predictivo que las aproximaciones GARCH bivariadas.

A pesar de la abundante literatura sobre el tema de la cobertura del riesgo, no existe un consenso concluyente acerca de un modelo de cobertura que supere a los demás modelos comparados para mejorar la cobertura en los diferentes mercados accionarios y futuros, así como en los diferentes horizontes de cobertura. Investigaciones recientes en la estimación de la razón de cobertura óptima han propuesto la adopción de modelos econométricos cada vez más complejos. De esta manera, el modelo de regresión cuantílica es una alternativa para estimar las RCMV y mejorar la efectividad de la cobertura en diferentes cuantiles de la distribución condicional de los rendimientos de los índices accionarios.

## Capítulo 3. Metodología

### 3.1 Descripción de los datos

A través de la historia, la Bolsa Mexicana de Valores (BMV) ha experimentado diversos cambios, innovaciones y transformaciones como consecuencia de la globalización de las economías, la liberación financiera, los avances tecnológicos y computacionales y la innovación de nuevos instrumentos financieros. Sin embargo, estos factores han hecho que el entorno financiero sea más riesgoso e incierto para las instituciones financieras, así como para los inversionistas institucionales e individuales que participan en la BMV, lo que ha conducido a buscar nuevos mecanismos para mitigar la exposición al riesgo en las inversiones de portafolio. En este contexto, los instrumentos financieros de cobertura son una alternativa efectiva para administrar el riesgo. Por lo que el Mercado de Derivados de México (MexDer) inició sus operaciones el 15 de abril de 1999 con la finalidad de proporcionar protección y cobertura a los diferentes agentes económicos a través de transacciones líquidas y transparentes con productos derivados financieros.

Actualmente, en el MexDer se listan diversos instrumentos financieros de cobertura para la administración de riesgos de diferentes activos subyacentes que cotizan en los mercados financieros. Entre ellos, se puede mencionar a los contratos de futuros y opciones financieras. En este tenor, la cobertura con contratos de futuros permite reducir la exposición al riesgo en periodos de alta volatilidad, puesto que los costos de transacción son relativamente bajos y el riesgo de incumplimiento es nulo.

Para el análisis de la efectividad de la cobertura, este trabajo utiliza los precios diarios de cierre de contado y futuros del Índice de Precios y Cotizaciones de la BMV (S&P/BMV IPC) listados en el MexDer. En la construcción continua de las series de los precios de los futuros se adoptó la regla habitual de la literatura, esto es, el contrato de futuros con vencimiento más próximo, es decir, 15 de marzo de 2013. Este procedimiento evita los efectos de precios volátiles como resultado de la expiración del contrato de futuros y la falta de liquidez en el mercado. Esto se atribuye a que en la medida que el contrato de futuros se acerca a su vencimiento, la concentración de la actividad del mercado se mueve inmediatamente al siguiente contrato con vencimiento más cercano. Esto hace que se

incremente automáticamente el volumen de operación y el interés abierto<sup>3</sup>. En la práctica, el proceso de transición al segundo contrato de futuros con vencimiento más próximo se lleva a cabo una semana antes del último día de operación del contrato de futuros por vencer (De Jesús, 2016).

El periodo de análisis cubre del 2 de enero de 2013 al 30 de diciembre de 2022, para un total de 2,514 observaciones. Todas las series financieras se obtuvieron de la base de datos de Bloomberg. La muestra total de los datos se divide en dos submuestras para llevar a cabo el análisis de la efectividad de la cobertura dentro y fuera de la muestra. El análisis dentro de la muestra está determinado por el periodo del 2 de enero de 2013 al 29 de diciembre de 2017. Mientras que el análisis fuera de la muestra abarca el periodo del 2 de enero de 2018 al 30 de diciembre de 2022, esto es, las últimas 1,258 observaciones de la muestra total. Asimismo, en el estudio se estiman las RCMV para los horizontes de tiempo diario, semanal y mensual, con el fin de examinar el impacto del horizonte de cobertura y en la efectividad de la cobertura del riesgo de precios en los portafolios de inversión.

Las Figuras 3.1 y 3.2 describen el comportamiento de los precios al contado y futuros sobre el S&P/BMV IPC. En ambos gráficos se puede observar una tendencia muy similar a través del tiempo entre las dos series financieras, lo que implica la existencia de una relación de largo plazo entre ambas variables financieras. Asimismo, los precios de contado y futuros exhiben importantes choques de mercado durante el periodo de análisis, es decir, diversas caídas bruscas o saltos en los niveles de las series financieras en periodos similares de tiempo. Estos choques están estrechamente relacionados con eventos económicos, financieros, políticos e incluso de carácter sanitario. Por ejemplo, la primera caída abrupta de las series de precios de contado y futuros ocurre el 24 de junio de 2013. Este hecho se atribuye a la incertidumbre de las señales de la Reserva Federal de Estados Unidos (Fed, por sus siglas en inglés), el cual fue provocado por el recorte

---

<sup>3</sup> El interés abierto es el principal indicador de liquidez del mercado de futuros, puesto que representa el número total de contratos de futuros que aún no han sido cerrados, liquidados o cancelados por una posición inversa (Hull, 2003).

anticipado en los estímulos económicos aplicado principalmente a las compras respaldadas en los bonos del tesoro e hipotecas.

La segunda caída pronunciada en ambas series financieras corresponde a la fecha del 14 de marzo de 2014. En este periodo de análisis, los mercados financieros internacionales fueron afectados por una mayor aversión al riesgo, la cual fue provocada por las tensiones bélicas entre Ucrania y Rusia por la integración del gobierno ucraniano a la Organización del Tratado del Atlántico Norte (OTAN). Por su parte, el tercer choque externo en las series financieras estudiadas se presentó el 26 de noviembre de 2018, derivado del conflicto entre Estados Unidos y México por la falta de medidas de seguridad para controlar las caravanas migrantes provenientes de Centro América. El 15 de agosto de 2019, ambas series financieras volvieron a experimentar una tendencia a la baja por la amenaza de una mayor desaceleración económica global aunada a la guerra comercial entre los países de Estados Unidos y China, lo que provocó nerviosismo y pánico entre los inversionistas de portafolio.



Figura 3.1. Comportamiento de los precios spot del índice S&P/BMV IPC 2013-2022.  
Fuente: Elaboración propia con datos de Bloomberg en Rstudio.






Figura 3.2. Comportamiento de los precios de los futuros sobre el índice S&P/BMV IPC.  
Fuente: Elaboración propia con datos de Bloomberg en Rstudio.

En marzo de 2020, los precios del S&P/BMV IPC y sus futuros experimentaron la caída más drástica cuando la crisis sanitaria de COVID-19 estalló y propago a todo el mundo desde la región de China. La pandemia de COVID-19 no solo colapsó el sistema de salud pública y la economía a nivel global, sino también el sistema financiero internacional. En este contexto, los mercados financieros internacionales experimentaron altos niveles de volatilidad y creciente incertidumbre, lo cual generó pánico entre los inversionistas y severas pérdidas como consecuencia de las fluctuaciones extremas en los precios de los activos financieros y el rápido flujo de la información hacia el sistema financiero global (Just y Echaust, 2020; Lyócsa et al., 2020; Smales, 2021).

Finalmente, otro descenso importante en los mercados de contado y de futuros del S&P/BMV IPC tuvo lugar el 30 de septiembre de 2022 debido a la creciente inflación experimentada en todo el mundo y el incremento en las tasas de interés por parte de la Fed de Estados Unidos como una medida restringida de la política monetaria. En consecuencia, estas caídas extremas inesperadas representaron severas pérdidas para las posiciones de mercado de los participantes en la BMV. De esta manera, la cobertura con contratos de futuros es una alternativa viable para reducir la exposición al riesgo de

mercado de los inversionistas, debido a sus bajos costos de transacción, alta liquidez, requerimientos de margen mínimos y el riesgo de incumplimiento nulo (Shrestha et al., 2018). Sin embargo, la efectividad de la cobertura con futuros financieros se puede alcanzar al proponer modelos de cobertura apropiados que capturen el fenómeno de la heterocedasticidad, los efectos asimétricos y eventos extremos generados por las crisis financieras y crisis sanitarias. En este sentido, el modelo de regresión por cuantiles es una alternativa para estimar razones de cobertura óptima y mejorar la efectividad de las estrategias de cobertura de los inversionistas individuales e institucionales en periodos de relativa calma y turbulencia financiera.

### **3.3 Modelo de regresión cuantílica**

Investigaciones recientes han profundizado en el análisis de la regresión lineal estándar, una técnica muy utilizada en el campo del análisis de datos. Las técnicas de regresión lineal estándar analizan los efectos entre un conjunto de variables explicativas y dependientes ajustando la media condicional  $E(Y|X)$ ; por lo que las relaciones estimadas describen solo parcialmente la relación de interés para la distribución condicional  $Y$ . En este sentido, la regresión lineal estándar supone que la relación entre variables es la misma en todos los puntos de la distribución, lo que produce una visión parcial del efecto de las variables explicativas sobre la variable dependiente. Este análisis limitado puede ampliarse ajustando la regresión lineal en otras medidas posicionales como los cuantiles. Este hecho permite obtener mayor información del horizonte de relaciones en diferentes puntos de la distribución (Gujarati, 2003; Weisberg, 2005).

En este marco, Koenker y Bassett (1978) introdujeron la idea de analizar la relación entre variables explicativas y variables dependientes para la mediana condicional  $\rho_{0.5}(Y|X)$ , la cual se extiende al cuantil  $\tau = 0.5$  para un cierto nivel de confianza  $\tau$ . Este concepto se puede extender a todos los cuantiles  $\tau$ , en donde  $\tau$  puede tomar valores dentro del intervalo  $(0,1)$ , que divide a  $Y$  en la proporción de  $\tau$  por debajo del cuantil y  $(1 - \tau)$  por encima del cuantil. De esta manera, la regresión por cuantiles consiste en ponderar y minimizar conceptualmente la distancia entre los datos previstos y los reales. De igual forma, el método de regresión cuantílica puede explicar con mayor precisión las relaciones

estocásticas de las variables analizadas, con solo describirlas con diferentes niveles de confianza.

Además, el método de regresión cuantílica es especialmente útil en situaciones en las que la distribución de la variable de respuesta es asimétrica o presenta colas pesadas, lo que puede dificultar la interpretación de los resultados obtenidos mediante métodos de regresión lineal tradicionales. Al modelar la relación entre las variables predictoras en diferentes cuantiles de la distribución condicional de la variable de respuesta. El modelo de regresión cuantílica permite obtener información más detallada sobre la relación entre las variables predictoras y la variable de respuesta. Asimismo, el modelo de regresión cuantílica es una aproximación más robusta frente a valores atípicos a diferencia del modelo de regresión por mínimos cuadrados y, consecuentemente, tiene una mejor aplicación a un gran abanico de datos, donde éstos no se comportan como una distribución normal (Ruiz, 2019).

En los estudios de carácter económico-financiero, las distribuciones de los datos financieros generalmente presentan típicamente colas más anchas, los cuales se encuentran en los cuantiles de interés más extremos. El análisis del valor en riesgo (VaR) es claro ejemplo de la importancia de la estimación precisa de los cuantiles inferiores y superiores. Los datos y estudios del ámbito económico-financiero se centran generalmente en variables que se pueden describir mediante una distribución de una ley potencial donde algunos eventos solo ocurren con una frecuencia muy baja. En 1895, Vilfredo Pareto describió esta relación para los datos de ingreso y riqueza. Los resultados condujeron a una gran serie de aplicaciones y a la generación de nuevas teorías en el tiempo, la cual es conocida hoy en día como la teoría de valores extremos.

De esta manera, el estudio de Jansen y de Vries (1991) es un claro ejemplo de la importancia del análisis de esta tipología de datos y comportamientos. Este análisis demostró que mediante el estudio de las colas de los rendimientos financieros. El desplome del mercado de Estados Unidos de 1987 no fue un valor atípico, sino más bien un evento raro predecible con datos previos. La predicción de eventos raros, pero con un

alto impacto, es especialmente importante en la gestión de riesgos y, de forma concreta, en la gestión de riesgos financiero. De acuerdo con los resultados de Koenker y Bassett (1978), el modelo de regresión cuantílica ha sido la piedra angular para la base del desarrollo de trabajos importantes en el campo de la economía financiera. Por ejemplo, la implementación de la medida de valor en riesgo condicional (CVaR, por sus siglas en inglés) propuesta de manera independiente por Chernozhukov y Umantsev (2001) y Engle y Manganelli (2004).

En la literatura sobre la cobertura con futuros, no existe evidencia contundente que confirme que el modelo MCO proporcione estimaciones inferiores de las RCMV para mejorar la efectividad de la cobertura del riesgo en los diferentes mercados accionarios y de futuros, así como en los diferentes horizontes de cobertura. Sin embargo, uno de los problemas de las RCMV estimadas con el método de regresión convencional es que la relación promedio entre los rendimientos de los precios de contado y los precios de futuros es estimada en forma constante a través del tiempo. En otras palabras, la estimación de las razones de cobertura es determinada para un solo punto de la distribución de rendimientos incondicional. En este sentido, Lien, Shrestha y Wu (2015) sugieren estimar las RCMV mediante la regresión cuantílica a fin de capturar su comportamiento dinámico a través del tiempo en los diferentes cuantiles de la distribución condicional.

Por consiguiente, en este estudio se propone utilizar el método de regresión cuantílica para estimar las razones de cobertura cuantílicas de mínima varianza. De esta manera, las razones de cobertura cuantílicas se estiman tomando como referencia el estimador del modelo MCO. Por otra parte, los rendimientos de los precios de contado y de futuros son definidos de la siguiente manera:

$$y_t = \Delta S_t, t = 1, \dots, T \text{ y } x_t = \Delta F_t, t = 1, \dots, T.$$

Por lo que los estimadores de mínimos cuadrados ordinarios del vector de parámetros  $[\alpha, \beta]$  se puede obtener de la siguiente manera:

$$[\hat{\alpha}, \hat{\beta}] = \arg \min_{\alpha, \beta} \sum_{t=1}^T [y_t - \mu_t(x_t; \alpha, \beta)]^2, \quad \mu_t(x_t; \alpha, \beta) = \alpha + \beta x_t, \quad (17)$$

donde la función estimada  $\mu_t(x_t; \alpha, \beta)$  es el estimador muestral de la esperanza condicional bajo el modelo lineal, es decir,  $E(y_t|x_t) = \mu_t(x_t; \alpha, \beta) = \alpha + \beta x_t$ . Por lo que el estimador de mínimos cuadrados depende de la relación promedio entre las variables  $y_t$  y  $x_t$ . Para determinar la función cuantil condicional y el vector de parámetros asociados, es importante definir a  $Y$  como una variable aleatoria con función de distribución acumulada continua  $F_Y(y) = P(Y \leq y)$ . De esta manera, el  $\tau$ -ésimo cuantil de  $Y$  está definido por:

$$q(\tau) = F_Y^{-1}(\tau) = \inf \{y: F_Y(y) \geq \tau\}, \quad (18)$$

donde  $\tau$  se encuentra en el intervalo cerrado  $[0,1]$ .

Si la función de pérdidas es definida como  $\rho_\tau(y) = y(\tau - I(y < 0))$ , entonces una solución para el problema de minimización se puede obtener en un cuantil específico (Koenker y Bassett, 1978). Por lo que la pérdida esperada de  $Y - u$  con respecto a  $u$  se puede minimizar de la siguiente manera:

$$q(\tau) = \arg \min_u E(\rho_\tau(Y - u))$$

$$q(\tau) = \arg \min_u \left[ (1 - \tau) \int_{-\infty}^u (y - u) dF_Y(y) + \tau \int_u^{\infty} (y - u) dF_Y(y) \right], \quad (19)$$

donde  $q(\tau)$  es el  $\tau$ -ésimo cuantil de la variable aleatoria  $Y$ , es decir,  $F_Y(q_\tau) = \tau$ .

De esta manera, una solución para el caso similar de la muestra está definida por el estimador del cuantil  $q(\tau)$ . De acuerdo con la estructura del modelo lineal, la función del  $\tau$ -ésimo cuantil condicional se puede expresar como  $q_{y_t|x_t}(\tau) = \alpha(\tau) + \beta(\tau)x_t$ . Para una

función de distribución de  $y_t$  dada, el vector de parámetros  $[\alpha(\tau), \beta(\tau)]$  se puede estimar de la siguiente manera:

$$[\alpha(\tau), \beta(\tau)] = \arg \min_{\alpha(\tau), \beta(\tau)} L(\alpha(\tau), \beta(\tau)) = \arg \min_{\alpha(\tau), \beta(\tau)} E[\rho_\tau(y_t - \alpha(\tau) - \beta(\tau)x_t)], \quad (20)$$

donde el valor esperado de la función de pérdida  $L(\alpha(\tau), \beta(\tau))$  es igual a  $[\rho_\tau(y_t - \alpha(\tau) - \beta(\tau)x_t)]$ . Además,  $\beta(\tau)$  es la razón de cobertura cuantílica para el cuantil  $\tau$ . Para el caso similar de la muestra, el estimador de los parámetros del vector  $[\alpha(\tau), \beta(\tau)]$  se obtiene de la siguiente forma:

$$[\hat{\alpha}(\tau), \hat{\beta}(\tau)] = \arg \min_{\alpha(\tau), \beta(\tau)} L_S(\alpha(\tau), \beta(\tau)) = \arg \min_{\alpha(\tau), \beta(\tau)} \sum_{t=1}^T [\rho_\tau(y_t - \alpha(\tau) - \beta(\tau)x_t)], \quad (21)$$

donde la función de pérdidas de la muestra  $L_S(\alpha(\tau), \beta(\tau))$  está definido por:

$$L_S(\alpha(\tau), \beta(\tau)) = \sum_{t=1}^T [\rho_\tau(y_t - \alpha(\tau) - \beta(\tau)x_t)]. \quad (22)$$

En este marco, los métodos de programación lineal son una alternativa para resolver eficientemente este problema de minimización. De acuerdo con el conjunto de soluciones interiores<sup>4</sup>, los estimadores cuantílicos del vector de parámetros  $[\hat{\alpha}(\tau), \hat{\beta}(\tau)]$  son asintóticamente normales bajo algunas condiciones de regularidad. No obstante, uno de los problemas en la regresión cuantílica se refiere a la dificultad para estimar directamente la matriz de varianza-covarianza. Por lo que la inferencia estadística de los parámetros de la regresión por cuantiles puede llevarse a cabo con el método Bootstrap (Lien et al., 2015). De esta manera, una propiedad importante del método de regresión cuantílica es que sus estimadores no son sensibles a la presencia de observaciones atípicas o

---

<sup>4</sup> Las soluciones interiores se pueden definir como el conjunto de soluciones factibles de un problema matemático. Estas soluciones son relevantes en situaciones donde las soluciones óptimas no están necesariamente en la frontera del conjunto factible. Además, estas soluciones pueden proporcionar información valiosa para la toma de decisiones (Bertsimas y Tsitsiklis, 2003).

extremas, las cuales son generadas en los periodos de extrema volatilidad. Finalmente, la relación entre los parámetros del modelo MCO y los parámetros del modelo de regresión cuantílica se puede definir de la siguiente manera:

$$\alpha = \int_0^1 \alpha(\tau) d\tau \quad \text{y} \quad \beta = \int_0^1 \beta(\tau) d\tau, \quad (23)$$

donde  $\alpha$  y  $\beta$  son los parámetros del modelo MCO.

### 3.4 Criterios de evaluación de la efectividad de la cobertura

#### 3.4.1 Índice de eficiencia de reducción de varianza

En la actualidad, los coberturistas no solo diseñan estrategias de cobertura para reducir la exposición al riesgo de precios, sino también analizan la efectividad de la cobertura que ayuda a reducir la varianza del portafolio de cobertura.

En consecuencia, la varianza del portafolio de cobertura se puede definir de la siguiente manera:

$$\text{VAR}(R_{C_t}) = \text{VAR}(\Delta S_t) - 2\beta \text{COV}(\Delta S_t, \Delta F_t) + \beta^2 \text{VAR}(\Delta F_t), \quad (24)$$

donde  $\text{VAR}(\Delta S_t)$ ,  $\text{VAR}(\Delta F_t)$ , y  $\text{COV}(\Delta S_t, \Delta F_t)$  denotan las varianzas y covarianza de los rendimientos de los precios de contado y de futuros, respectivamente.

Por su parte, en la literatura existen diferentes criterios para evaluar el desempeño de los modelos de cobertura. Ku, Chen y Chen (2007) proponen el índice eficiente de cobertura (ICE) para la evaluación de la efectividad de la cobertura en términos de reducción de la varianza del portafolio de cobertura. El ICE se determina a partir de la diferencia entre la varianza del portafolio sin cobertura y la varianza del portafolio con cobertura dividido entre la varianza del portafolio sin cobertura. Por lo que el desempeño de los modelos de cobertura se puede medir de la siguiente manera:

$$\text{ICE} = \left[ \frac{\text{VAR}(\Delta S_t) - \text{VAR}(R_{C_t})}{\text{VAR}(\Delta S_t)} \right] \times 100. \quad (25)$$

En general, un valor alto del ICE indica que el desempeño del modelo de cobertura es superior para reducir la varianza de los rendimientos del portafolio de cobertura. En este sentido, el modelo de cobertura elimina totalmente el riesgo cuando el valor del ICE es igual a 100.

### **3.4.2 Valor en riesgo**

Otro criterio importante para evaluar el desempeño de los modelos de cobertura es la medida valor en riesgo (VaR). El VaR es una medida ampliamente utilizada en el mundo financiero para evaluar el riesgo asociado a una posición de mercado o a un portafolio de inversión. Esta medida tomo fuerza y reconocimiento como herramienta para la medición del riesgo de mercado y otros tipos de riesgos financieros debido a la recomendación de las autoridades regulatorias, asesores en la industria financiera y administradores de riesgos del sector privado a mediados de los años 90s. En julio de 1993, el uso de la medida VaR fue recomendada por primera vez como un informe diario del Grupo de los Treinta (G30) en el estudio de Productos Derivados: Prácticas y Principios. De esta manera, este selecto grupo de reconocidas personalidades del ámbito financiero argumentaron que la medida VaR es un modelo confiable para la estimación del riesgo de mercado, incluso para portafolios de inversión que contienen productos derivados tales como opciones financieras (Fallon, 1996).

Actualmente, el VaR es usado por diversas autoridades regulatorias como medida de referencia de riesgo, entre los que destacan Basilea I, Basilea II, Solvencia II y NAIC (National Association of Insurance Commissioners). Asimismo, esta herramienta estadística es usada por todo tipo de instituciones financieras debido a su fácil implementación e interpretación de los resultados. Esta medida de riesgo estima en términos monetarios la máxima pérdida que la organización está dispuesta a asumir en un horizonte de tiempo dado un nivel de confianza. La estimación del riesgo basado en el VaR no depende del comportamiento de los precios de los activos financieros, sino del comportamiento de los factores de riesgos lineales y no lineales que afectan el desempeño financiero del portafolio de inversión (Ríos, 2014).



En la literatura, los modelos VaR se clasifican en métodos paramétricos y no paramétricos debido a los supuestos estadísticos y financieros para su implementación. Para fines de este estudio, el modelo paramétrico delta-normal será utilizado para calcular el VaR y evaluar el desempeño de los modelos de cobertura. El método delta-normal asume que el comportamiento asintótico de los cambios en los factores de riesgo sigue una distribución normal. Por lo que la precisión de las pérdidas estimadas depende directamente de los supuestos asumidos en el modelo de riesgo implementado. Frecuentemente, el supuesto de la distribución de pérdidas y ganancias sigue una distribución normal facilita en gran medida la estimación del valor en riesgo del portafolio del portafolio de inversión. Asimismo, el uso de modelos paramétricos es particularmente ideal cuando el desempeño del portafolio de inversión depende del comportamiento de factores de riesgo lineales, tales como índices bursátiles, bonos, acciones, materias (commodities) y monedas (Mariño y Melo, 2016).

De manera formal, el VaR se define como la máxima pérdida esperada de una posición de mercado o de un portafolio de inversión durante un horizonte de tiempo dado un nivel de confianza (Jorion, 2001). Los inversionistas utilizan el VaR para comprender cuánto podrían perder en condiciones desfavorables. En el contexto de la cobertura con futuros, el VaR se utiliza para evaluar el desempeño de los modelos para mejorar las estrategias de cobertura del riesgo de las posiciones de mercado. Asimismo, el VaR captura los efectos asimétricos derivado de las posiciones corta y larga con contratos de futuros financieros (Zhou, 2016).

En este sentido, el VaR del portafolio de cobertura se puede estimar de la siguiente manera:

$$\text{VaR}(R_{C_t}) = E(R_{C_t}) + Z_\alpha \sqrt{\text{VAR}(R_{C_t})}, \quad (26)$$

donde  $Z_\alpha$  es el valor crítico de cola izquierda de la distribución normal para un nivel de confianza  $\alpha$ . En la práctica,  $\alpha$  suele establecerse entre 5% y 1%. Si la estrategia de

cobertura es efectiva, el VaR del portafolio con cobertura debería ser menor que el VaR del portafolio sin cobertura.

La evaluación de la efectividad de la cobertura se hace mediante el cálculo del índice de eficiencia de reducción del riesgo del portafolio de cobertura. Para ello, es necesario estimar también el valor en riesgo del portafolio de la posición sin cobertura, es decir,  $(\text{VaR}(\Delta S_t))$ . En consecuencia, el  $\text{VaR}(\Delta S_t)$  se calcula de la forma siguiente:

$$\text{VaR}(\Delta S_t) = E(\Delta S_t) + Z_\alpha \sqrt{\text{VAR}(\Delta S_t)}, \quad (27)$$

Con lo anterior, índice de eficiencia de reducción del riesgo,  $ICE_{VaR}$  es una medida cuantitativa que indica cuanto el nivel del riesgo del portafolio se ha reducido para mejorar la efectividad de la cobertura. Si el  $ICE_{VaR}$  alcanza un valor del 0%, este hecho indica que la cobertura no ha tenido ningún impacto en la reducción del riesgo. Por otro lado, un alto  $ICE_{VaR}$  revela que la cobertura ha sido efectiva en la reducción del riesgo del portafolio de cobertura. En este contexto, el cálculo del  $ICE_{VaR}$  se puede determinar de la siguiente manera:

$$ICE_{VaR} = \left[ \frac{\text{VaR}(\Delta S_t) - \text{VaR}(R_{C_t})}{\text{VaR}(\Delta S_t)} \right] \times 100. \quad (28)$$

De esta manera, el  $ICE_{VaR}$  proporciona una herramienta robusta a los inversionistas y administradores de portafolio para evaluar la efectividad de las estrategias de cobertura del riesgo con futuros financieros. Este proceso es primordial en la toma de decisiones informadas sobre el beneficio real de la cobertura en términos de protección contra la volatilidad del mercado. Además, el  $ICE_{VaR}$  ofrece una medida cuantitativa que facilita la comparación del desempeño de los modelos de cobertura de MCO y cuantifica. Esta herramienta permite identificar la mejor estrategia de cobertura para reducir la exposición al riesgo tomando como referencia el riesgo del portafolio de inversión sin cobertura.

## **Capítulo 4. Evidencia para la Bolsa Mexicana de Valores**

### **4.1 Estadísticas descriptivas**

En esta sección se muestran las estadísticas básicas y pruebas de raíces unitarias y de estacionariedad para los niveles y rendimientos de los precios spot y futuros para el periodo del 2 de enero del 2013 al 30 de diciembre del 2022. Los resultados del Panel A de la Tabla 4.1 muestran que el promedio de los rendimientos es positivo, pero pequeño para ambas series financieras. Por lo que no hay una tendencia marcada en ninguna dirección específica. Esta característica es esencial porque implica una neutralidad en los rendimientos de las series de precios spot y futuros. Sin embargo, el valor de la desviación estándar es alta en ambas series financieras, particularmente en los rendimientos de los futuros financieros. Este hallazgo revela que los inversionistas experimentaron una mayor exposición al riesgo como consecuencia de los diversos eventos que han hecho que los precios presenten fluctuaciones altas.

Por otro lado, las series de los rendimientos presentan efectos asimétricos negativos, lo que indica que los rendimientos extremos negativos tienen mayor probabilidad de ocurrir que los rendimientos positivos. Asimismo, los rendimientos de ambas series financiera presentan exceso de curtosis. Este hecho confirma que las colas de las distribuciones de rendimientos de los precios de contado y futuros son más anchas y largas que las colas de la distribución normal. De hecho, el valor del estadístico de la prueba Jarque-Bera confirma que la hipótesis nula de que los rendimientos de los precios de contado y futuros siguen una distribución normal es rechazada. En este tenor, la falta de normalidad implica que métodos basados en la suposición de normalidad pueden no ser apropiados, y es fundamental considerar enfoques más robustos para capturar las características observadas en las series financieras.

Las pruebas de Dickey-Fuller y Phillips-Perron se utilizan para validar las condiciones de estacionariedad en los niveles de los precios y rendimientos, y sus resultados se presentan en el Panel B de la Tabla 2. En primera instancia, los resultados muestran que los niveles de los precios tienen al menos una raíz unitaria, esto es, ambas series financieras no son estacionarias a un nivel de significancia del 5%, lo que implica que existe una relación de

largo plazo. Por otra parte, el estadístico de la prueba de Dickey-Fuller indica que las primeras diferencias de los rendimientos de los precios de contado y futuros son estacionarias.

Tabla 4.1. Estadísticas básicas de los rendimientos de los precios al contado y futuros.

	Spot	Futuros
<b>Panel A. Estadísticas básicas</b>		
Media	0.0036	0.0036
Desviación estándar	0.9820	1.0211
Mínimo	-6.6381	-7.1493
25%	-0.5262	-0.5749
50%	0.0028	0.0044
75%	0.5599	0.5883
Máximo	4.7439	4.1330
Sesgo	-0.3660	-0.3414
Curtosis	3.3664	3.1589
Jarque-Bera	1242.7408	1093.6855
<b>Panel B. Pruebas de raíz unitaria</b>		
Niveles		
Dickey-Fuller	-2.6374**	-2.6116**
Phillips-Perron	1.1943**	1.2365**
Primeras diferencias		
Dickey-Fuller	-17.7038	-17.9523
Phillips-Perron	0.0869	0.0461

Nota: Los términos \* y \*\* denotan significancia a un nivel del 5% y 1% respectivamente.

Fuente: Elaboración propia con datos de Bloomberg.

Por su parte, la Figura 4.1 presenta el comportamiento dinámico de los rendimientos de los precios de contado y futuros del índice S&P/BMV IPC para el periodo 2013-2022, en donde es posible observar la presencia de heterocedasticidad y creciente volatilidad como resultado de la ocurrencia de diversos eventos extremos en el periodo de análisis,

particularmente durante la crisis sanitaria de Covid-19 cuando los rendimientos de los precios de contado y de futuros alcanzaron valores negativos de -6.63% y -7.14%, respectivamente.




Figura 4. 1. Rendimientos diarios de los precios spot y futuros del índice S&P/BMV IPC. Fuente: Elaboración propia con datos de Bloomberg en Python.

La crisis de la pandemia de COVID-19 generó creciente incertidumbre y pánico entre los inversionistas, lo que propició desplomes en los precios de las acciones en la BMV y una marcada caída en los índices bursátiles internacionales. De esta manera, esta clase de acontecimientos sirve de enseñanza a los inversionistas de la rapidez con que la percepción del riesgo puede cambiar a través del tiempo, y de la necesaria importancia de las estrategias de cobertura para amortiguar los efectos negativos. Durante estos periodos de crisis e inestabilidad financiera se puede observar que los rendimientos experimentaron una sucesión de movimientos atípicos positivos y negativos en intervalos de tiempo relativamente cortos.

#### **4.2 Estimación de las razones de cobertura dentro de la muestra**

En esta sección se presentan los resultados de la estimación de las RCMV dentro de la muestra para el periodo del 3 de enero del 2013 al 29 de diciembre del 2017. En la Tabla 4.2 se reportan los coeficientes constantes  $\alpha$  y estimados por el modelo MCO y regresión cuantílica para el mercado de futuros del índice S&P/BMV IPC para horizontes de cobertura diario, semanal y mensual. Para el horizonte diario, 18 de los 20 cuantiles son significativos al 1% con valores mixtos debido a que en la medida que los cuantiles se alejan del cuantil 0.50. Los valores de los coeficientes se incrementan hasta alcanzar el valor de 0.4160, mientras que el coeficiente de MCO se mantiene negativo. Los resultados son muy similares para los horizontes de cobertura semanal y mensual. Por ejemplo, los coeficientes constantes  $\alpha$  son significativos a un nivel del 1% en 16 cuantiles para el horizonte de cobertura semanal y sólo 8 cuantiles para el horizonte mensual. En contraste, los coeficientes del modelo MCO no son significativos en ninguno de los horizontes de cobertura. Otro hecho importante de resaltar es que en la medida que se incrementa el horizonte de cobertura se observa un aumento significativo en los errores estándar estimados. Este fenómeno se observa en cualquier horizonte de cobertura, lo que se atribuye a una disminución del tamaño de la muestra.

Tabla 4.2. Estimaciones del término constante de ambas regresiones dentro de la muestra.

	Diario		Semanal		Mensual	
0.05	-0.26532**	(0.01352)	-0.47053**	(0.04386)	-0.65798	(Nd)
0.10	-0.18826**	(0.00917)	-0.33245**	(0.04786)	-0.63579**	(0.11690)
0.15	-0.14329**	(0.00662)	-0.20112**	(0.02761)	-0.47798**	(0.13435)
0.20	-0.11391**	(0.00598)	-0.15785**	(0.02258)	-0.20541**	(0.07043)
0.25	-0.09255**	(0.00576)	-0.11648**	(0.02078)	-0.18770*	(0.07194)
0.30	-0.06589**	(0.00538)	-0.07844**	(0.01937)	-0.10669	(0.06559)
0.35	-0.04752**	(0.00528)	-0.04181*	(0.01793)	-0.05445	(0.06128)
0.40	-0.03167**	(0.00508)	-0.01564	(0.01721)	-0.01341	(0.06085)
0.45	-0.01173*	(0.00485)	0.00875	(0.01669)	0.02328	(0.05971)
0.50	0.00475	(0.00477)	0.04217**	(0.01622)	0.06047	(0.05887)
0.55	0.02036**	(0.00478)	0.05995**	(0.01575)	0.06278	(0.05844)
0.60	0.03708**	(0.00480)	0.08434**	(0.01540)	0.11638*	(0.05647)
0.65	0.05250**	(0.00494)	0.10269**	(0.01499)	0.12440*	(0.05479)
0.70	0.07046**	(0.00533)	0.13045**	(0.01459)	0.16089**	(0.05322)
0.75	0.09829**	(0.00625)	0.15961**	(0.01441)	0.22604**	(0.05403)
0.80	0.12460**	(0.00684)	0.18956**	(0.01480)	0.26535**	(0.05340)
0.85	0.15855**	(0.00701)	0.20778**	(0.01449)	0.35143**	(0.05918)
0.90	0.19260**	(0.00730)	0.24557**	(0.01557)	0.41420**	(0.06304)
0.95	0.26710**	(0.01191)	0.29879**	(0.01827)	0.47916	(Nd)
0.99	0.41602**	(0.02390)	0.53842	(Nd)	0.54322	(Nd)
MCO	-0.00009	(0.00500)	-0.00240	(0.01600)	-0.00860	(0.04700)

Nota: Esta tabla reporta los resultados estimados del coeficiente constante de las regresiones MCO y cuantílica para diferentes cuantiles. El término Nd significa no disponible, los valores entre paréntesis denotan a los errores estándar. Los términos \* y \*\* denotan significancia a un nivel del 5% y 1%, respectivamente.

Fuente: Elaboración propia con datos de Bloomberg.

En la Tabla 4.3 se muestran los resultados de la estimación de las RCMV mediante los modelos MCO y regresión cuantílica, así como su significancia y sus errores estándar para los 3 horizontes de cobertura. Las RCMV estimadas son significativas estadísticamente para los diferentes cuantiles y horizontes de cobertura. Además, una RCMV cercana a 1 indica que la posición de futuros se está utilizando de manera más conservadora para la cobertura de la posición de contado. Este hecho indica que la implementación de medidas sólidas de cobertura para amortiguar los efectos negativos generados por las posibles fluctuaciones el mercado de contado. Por otro lado, cuando la RCMV es menor a 1, la estrategia de cobertura con futuros es más agresiva para reducir la exposición al riesgo.

Tabla 4.3. Resultados de la estimación de las RCMV para los 3 horizontes de cobertura.

	Diario		Semanal		Mensual	
0.05	0.93140**	(0.02243)	0.97097**	(0.02380)	0.89519	(Nd)
0.10	0.94583**	(0.01408)	<b>0.99599**</b>	(0.02398)	0.89630**	(0.05131)
0.15	0.94663**	(0.00941)	0.97895**	(0.01379)	0.94876**	(0.04973)
0.20	0.94596**	(0.00820)	0.97999**	(0.01223)	0.93438**	(0.02577)
0.25	0.94464**	(0.00748)	0.98062**	(0.01110)	0.93065**	(0.02495)
0.30	0.94660**	(0.00679)	0.97235**	(0.01023)	0.95401**	(0.02189)
0.35	0.94794**	(0.00647)	0.96316**	(0.00920)	0.96162**	(0.02029)
0.40	0.94355**	(0.00606)	0.96156**	(0.00882)	0.95640**	(0.02084)
0.45	0.94602**	(0.00567)	0.96299**	(0.00865)	0.96314**	(0.02035)
0.50	0.94834**	(0.00550)	0.96626**	(0.00846)	0.96997**	(0.02032)
0.55	<b>0.95206**</b>	(0.00544)	0.96290**	(0.00829)	0.96944**	(0.02055)
0.60	0.95174**	(0.00538)	0.96194**	(0.00810)	0.96738**	(0.02057)
0.65	0.95076**	(0.00550)	0.95993**	(0.00785)	0.96800**	(0.01870)
0.70	0.94719**	(0.00588)	0.95566**	(0.00768)	0.96954**	(0.01738)
0.75	0.94469**	(0.00698)	0.95885**	(0.00743)	0.96589**	(0.01638)
0.80	0.94848**	(0.00774)	0.95946**	(0.00691)	0.96850**	(0.01562)
0.85	0.95165**	(0.00799)	0.95989**	(0.00657)	<b>0.99307**</b>	(0.01623)
0.90	0.94713**	(0.00849)	0.96237**	(0.00750)	0.96816**	(0.01812)
0.95	<b>0.95981**</b>	(0.01498)	0.96331**	(0.00869)	0.96781	(Nd)
0.99	0.94286**	(0.03434)	<b>1.02293</b>	(Nd)	0.98400	(Nd)
MCO	0.94050**	(0.00600)	0.96590**	(0.00800)	0.95430**	(0.01600)

Nota: Esta tabla reporta los resultados estimados del coeficiente de las RCMV de las regresiones MCO y cuantílica para diferentes cuantiles. El término Nd significa no disponible, los valores entre paréntesis denotan a los errores estándar. Los términos \* y \*\* denotan significancia a un nivel del 5% y 1%, respectivamente.

Fuente: Elaboración propia con datos de Bloomberg.

La evidencia empírica muestra que la mayoría de las RCMV son significativos a un nivel del 5% para horizonte de un día, incluso la razón de cobertura del método MCO. Otro hecho importante es que las RCMV cuantílicas son relativamente más altas que las del modelo MCO en la mayoría de los cuantiles para el horizonte de cobertura diario, especialmente para el 0.55 y 0.95. Aunque la razón de cobertura de MCO es mayor para el cuantil 0.05. Para el horizonte de cobertura semanal, las RCMV cuantílicas son más altas que las del método tradicional para los cuantiles inferiores. Para el horizonte de cobertura semanal, la mayoría de las RCMV cuantílicas y de MCO son estadísticamente significativas, excepto para el cuantil extremo del 0.99. Sin embargo, el método de regresión cuantílica presenta estimaciones de las RCMV por debajo del 0.96590 a partir



del cuantil 0.35 y hasta el cuantil 0.95 en comparación con el modelo MCO, debido a que la RCMV del cuantil 0.99 tiene un valor del 1.02293. Este hecho indica que la estrategia de la cobertura con futuros sobreprotege la posición de contado del portafolio réplica del índice accionario S&P/BMV IPC.

En cuanto al horizonte de cobertura mensual, las RCMV son estadísticamente significativas a un nivel de 5% para la mayoría de los cuantiles, excepto para los cuantiles extremos inferiores y superiores. Por su parte, las RCMV estimadas por el modelo MCO presentan valores más conservadores con respecto a las RCMV cuantílicas en los cuantiles de 0.05 a 0.35. No obstante, las RCMV estimadas por el modelo de regresión cuantílica presentan valores más altos a las estimadas por el método MCO para los cuantiles mayores o iguales a 0.40, particularmente para el cuantil 0.85. Además, las RCMV estimadas dentro de la muestra se incrementan en la medida que el horizonte de cobertura se incrementa. Estos hallazgos están en línea con los resultados del trabajo de De Jesús et al. 2021.

Por su parte, la Figura 4.2 muestra tres gráficas que comparan las RCMV en todos los cuantiles estudiados para los tres horizontes de cobertura. La línea azul conecta los puntos con las RCMV estimadas por método de regresión cuantílica, mientras que la línea roja punteada representa el comportamiento de la RCMV estimada por el método MCO. Estas gráficas son importantes para entender como las razones de cobertura cambian en diferentes puntos de la distribución condicional de rendimientos del índice accionario S&P/BMV IPC. Estos hallazgos pueden ayudar a los inversionistas a rebalancear el portafolio de cobertura para minimizar la exposición al riesgo de precios, particularmente en los cuantiles inferiores y superiores.


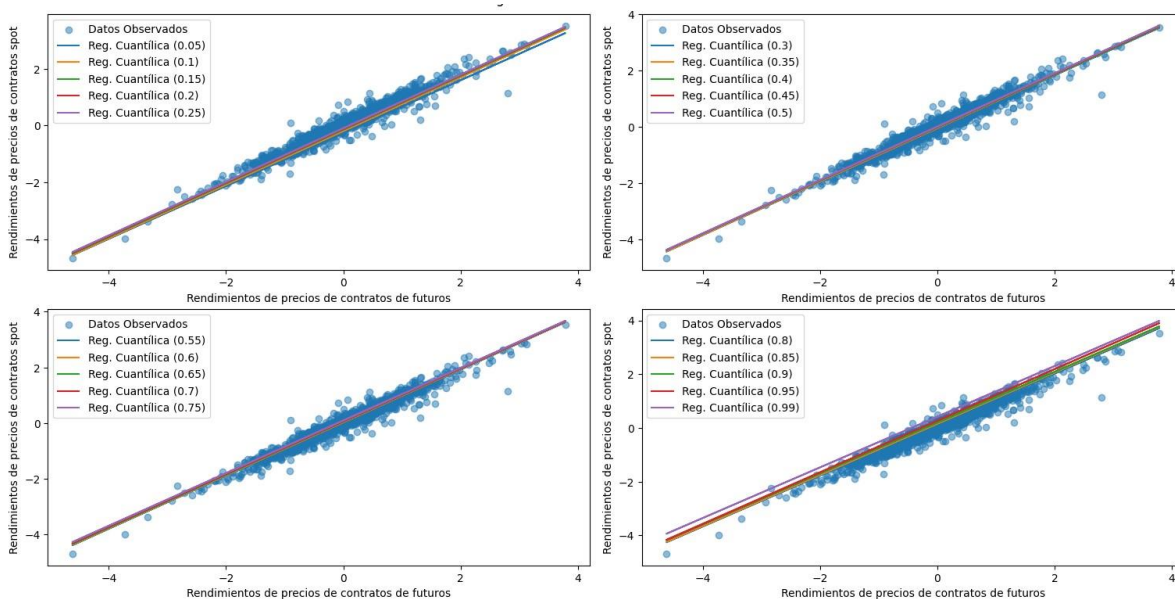


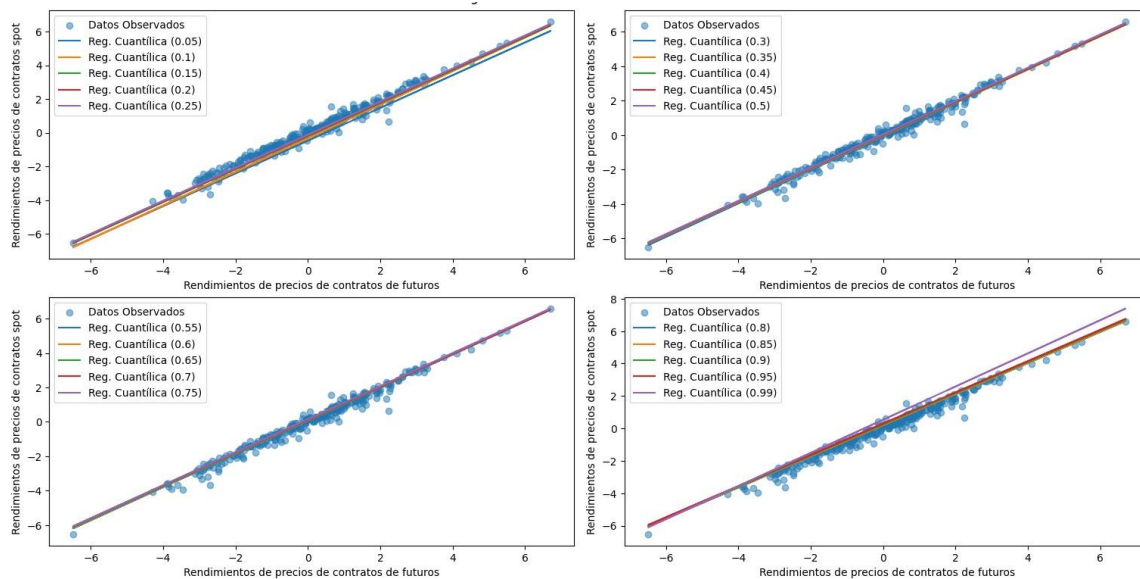
Figura 4. 2. RCMV cuantílicas y MCO para los tres horizontes de cobertura. Fuente: Elaboración propia con datos de Bloomberg en Python.

Por otro lado, la Figura 4.3 muestra los puntos de dispersión de los rendimientos de los precios de contado y futuros, así como de las líneas de tendencia de la regresión cuantílica para los 20 cuantiles estudiados. Los puntos se encuentran dispersos en función de los valores de los rendimientos de los precios de los futuros y rendimientos de los precios de contado. Este gráfico permite visualizar la distribución conjunta de ambas variables financieras. Asimismo, la línea de la tendencia de la regresión por cuantiles muestra la relación entre las dos variables para cada uno de los cuantiles especificados. Las líneas de tendencia pueden inclinarse hacia arriba o hacia abajo e incluso cambiar de pendiente a través de los diferentes cuantiles. Este hecho permite capturar apropiadamente la variación de la relación entre los rendimientos de los precios de contado y futuros en diferentes partes de la distribución condicional. Por otra parte, las líneas de tendencia son relativamente planas a través de los cuantiles, lo que demuestra que la relación entre los rendimientos de contado y futuros es bastante estable en la mayor parte de la distribución condicional. De hecho, este hallazgo confirma la robustez del modelo de regresión cuantílica para capturar los efectos asimétricos y eventos extremos observados en las series financieras.

Panel A: Rendimientos diarios.



Panel B: Rendimientos semanales.



Panel C: Rendimientos mensuales.

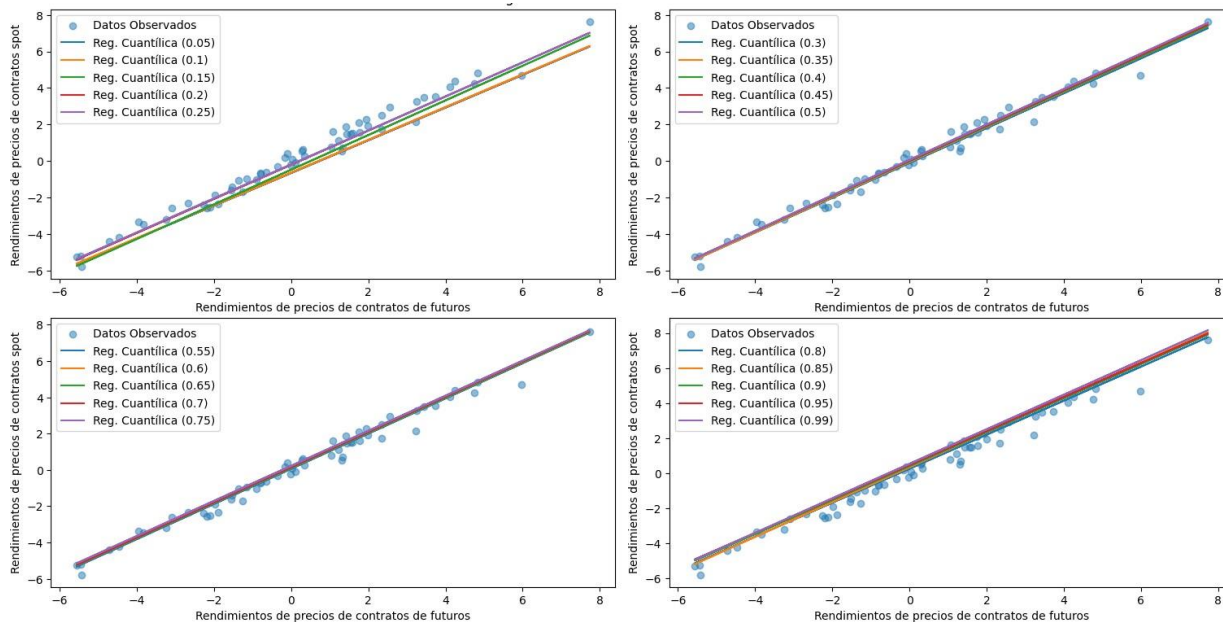


Figura 4.3. Gráfico de dispersión y líneas de tendencia de la regresión cuantílica para los diferentes cuantiles.

Fuente: Elaboración propia con datos de Bloomberg en Python.

### 4.3 Estimación de las razones de cobertura fuera de la muestra

En esta sección se analiza el comportamiento dinámico de las RCMV estimadas fuera de la muestra para el periodo del 2 de enero de 2018 al 30 de diciembre de 2022. En este caso, los parámetros de los modelos de cobertura cuantílica y MCO son reestimados

utilizando una ventana móvil fija del tamaño de 1,258 observaciones. El procedimiento consiste en remover la observación más remota y agregar la observación más reciente al periodo muestral dentro de la muestra. De esta manera, el tamaño de la muestra se mantiene fijo durante la reestimación de los modelos y las estimaciones de las razones de cobertura óptima no se traslapan.

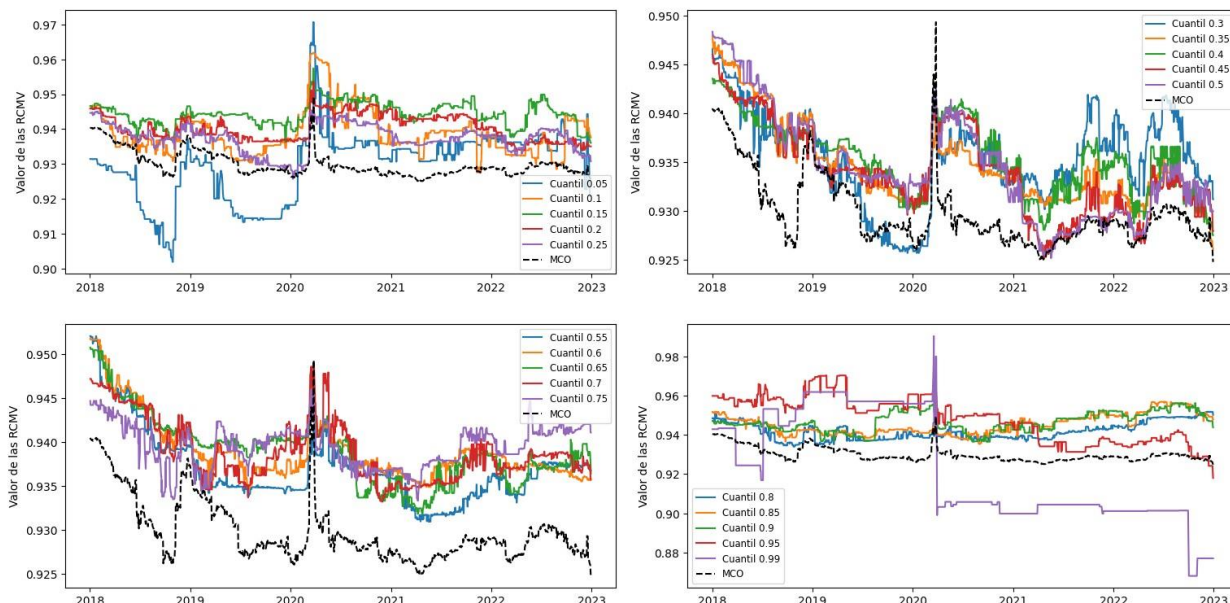


Figura 4.4. Estimación de las RCMV diarias cuantílicas y por el modelo de MCO.  
Fuente: Elaboración propia con datos de Bloomberg en Python.

El comportamiento dinámico de las RCMV estimadas se ilustran en las Figuras 4.4, 4.5 y 4.6, respectivamente. En cada ilustración se comparan las estimaciones fuera de la muestra de las RCMV obtenidas por los modelos MCO y regresión cuantílica para cada uno de los tres horizontes de cobertura. En todas las figuras se observa que el modelo de regresión cuantílica proporciona RCMV más conservadoras para la mayoría de los cuantiles. Además, las razones de cobertura cuantílicas son más volátiles que las del modelo MCO, principalmente en los cuantiles extremos inferiores de la distribución condicional de rendimientos del índice accionario S&P/BMV IPC. En este contexto, la tendencia de las RCMV presenta importantes caídas en los horizontes de cobertura diario y semanal en el periodo 2018-2019. Mientras que en los tres horizontes de cobertura se observa que el valor de las RCMV se incrementa en el periodo de marzo 2020 cuando la

pandemia de la crisis sanitaria de Covid-19 se agravó por el pánico del incremento de las muertes en todo el mundo.

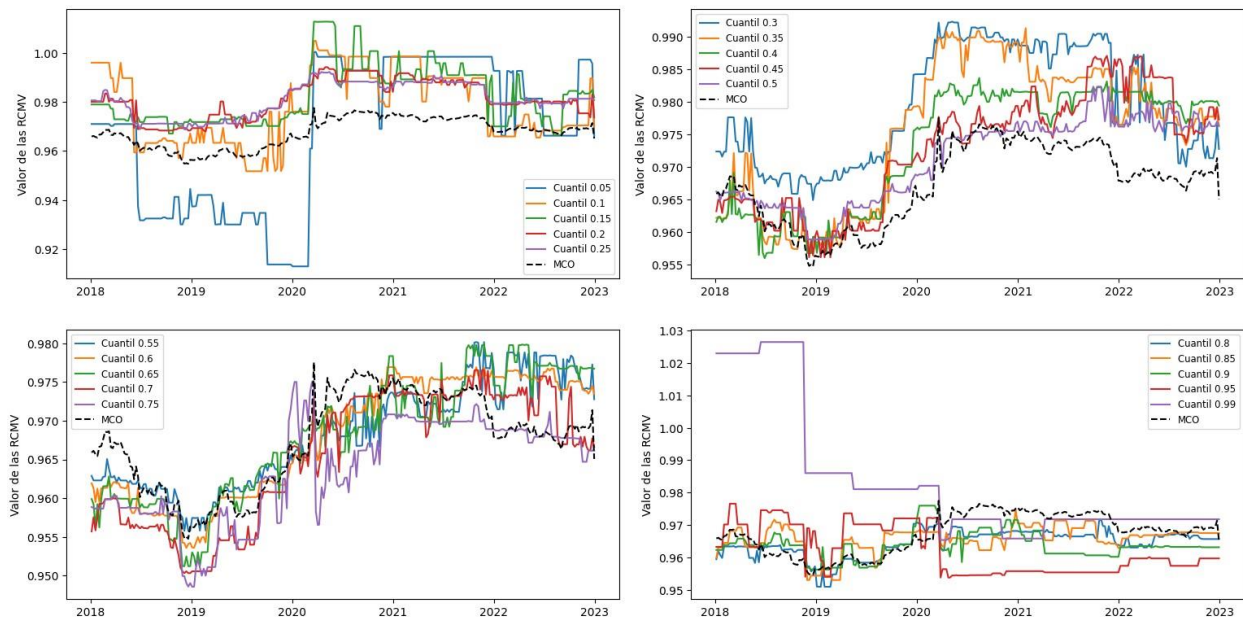


Figura 4.5. Estimación de las RCMV semanales cuantílicas y por el modelo de MCO.  
Fuente: Elaboración propia con datos de Bloomberg en Python.

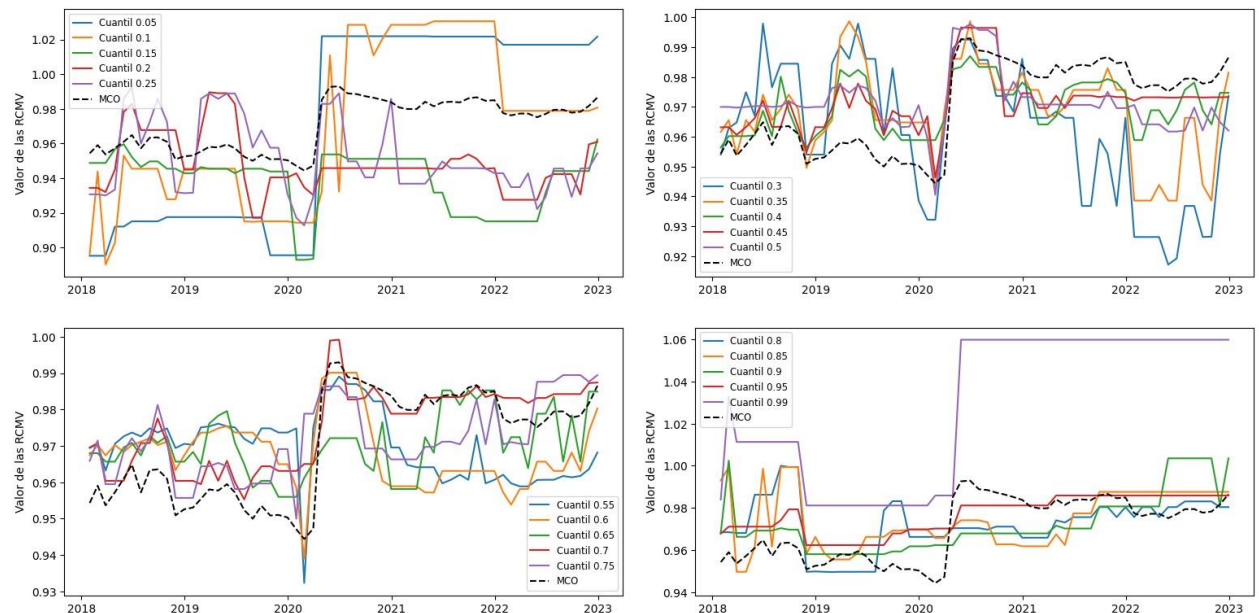


Figura 4.6. Estimación de las RCMV mensuales cuantílicas y por el modelo de MCO.  
Fuente: Elaboración propia con datos de Bloomberg en Python.

Asimismo, los resultados de las estadísticas básicas de las RCMV estimadas fuera de la muestra por los modelos MCO y regresión cuantílica son reportados en las Tablas 4.4, 4.5 y 4.6 para los horizontes de cobertura diario, semanal y mensual, respectivamente. En este tenor, las RCMV cuantílicas para los datos diarios presenta valores promedios más grandes a los valores estimados por el modelo MCO en 18 de los 20 cuantiles. Mientras que los valores de las RCMV cuantílicas son ligeramente más pequeños que las razones de cobertura del modelo MCO en los cuantiles extremos de 0.05 y 0.99.

No obstante, el valor promedio de las RCMV estimadas por el método MCO es más grande en el cuantil inferior de 0.05 y para seis cuantiles superiores que se encuentran entre 0.70 y 0.95 de la distribución condicional utilizando los rendimientos semanales de ambos mercados. Por su parte, el valor promedio de las RCMV cuantílicas estimadas son relativamente más pequeños que los valores promedio del método MCO en 10 cuantiles para el horizonte de cobertura mensual, especialmente en los cuantiles inferiores de la distribución condicional de rendimientos del índice accionario S&P/BMV IPC. En consecuencia, la variación en los valores promedios de las RCMV en los horizontes diarios, semanales y mensuales confirman el comportamiento dinámico de las estrategias de cobertura a través del tiempo. Aunque los resultados muestran que las estrategias de cobertura para horizontes de tiempo de corto plazo suelen ser más agresivas o especulativas. Por esta razón los promedios de las RCMV diarias son inferiores a las razones de cobertura de horizontes semanales y mensuales.

Por otro lado, las desviaciones estándar de las RCMV estimadas fuera de la muestra proporcionan información sobre la variabilidad o dispersión de las razones de cobertura en diferentes cuantiles y horizontes de tiempo. Un hecho importante de resaltar es que la desviación estándar solo es inferior a la del modelo MCO para los cuantiles de 0.15 y 0.75 con valores de 0.0032 y 0.0024 contra 0.0036 para el horizonte de cobertura diario. Mientras que el resto de los 19 cuantiles presentan desviaciones superiores, particularmente en el cuantil 0.9 con una desviación estándar de 0.0273.

Tabla 4.4. Resultados de las estimaciones diarias de las RCMV fuera de la muestra.

Cuantil	Media	Desviación	Mínimo	25%	50%	75%	Máximo
0.05	0.9296	0.0100	0.9019	0.9235	0.9327	0.9362	0.9707
0.10	0.9387	0.0065	0.9276	0.9347	0.9371	0.9422	0.9619
0.15	0.9444	0.0032	0.9360	0.9426	0.9443	0.9466	0.9574
0.20	0.9403	0.0038	0.9335	0.9368	0.9397	0.9435	0.9536
0.25	0.9374	0.0040	0.9257	0.9356	0.9378	0.9399	0.9477
0.30	0.9354	0.0046	0.9257	0.9329	0.9360	0.9382	0.9466
0.35	0.9347	0.0042	0.9261	0.9316	0.9336	0.9361	0.9479
0.40	0.9354	0.0037	0.9275	0.9325	0.9354	0.9383	0.9435
0.45	0.9341	0.0046	0.9253	0.9303	0.9340	0.9380	0.9460
0.50	0.9345	0.0054	0.9252	0.9300	0.9335	0.9383	0.9483
0.55	0.9370	0.0040	0.9310	0.9347	0.9361	0.9385	0.9521
0.60	0.9391	0.0035	0.9348	0.9369	0.9379	0.9400	0.9517
0.65	0.9391	0.0038	0.9318	0.9368	0.9393	0.9406	0.9508
0.70	0.9389	0.0035	0.9332	0.9362	0.9382	0.9409	0.9488
0.75	0.9395	0.0024	0.9333	0.9378	0.9398	0.9413	0.9460
0.80	0.9417	0.0044	0.9339	0.9380	0.9410	0.9448	0.9518
0.85	0.9453	0.0052	0.9352	0.9410	0.9442	0.9491	0.9568
0.90	0.9465	0.0051	0.9365	0.9426	0.9459	0.9511	0.9562
0.95	0.9481	0.0115	0.9180	0.9366	0.9503	0.9568	0.9702
0.99	0.9230	0.0273	0.8681	0.9014	0.9058	0.9558	0.9903
MCO	0.9299	0.0036	0.9248	0.9274	0.9287	0.9310	0.9493

Fuente: Elaboración propia con datos de Bloomberg.



Tabla 4.5. Resultados de las estimaciones semanales de las RCMV fuera de la muestra.

Cuantil	Media	Desviación	Mínimo	25%	50%	75%	Máximo
0.05	0.9674	0.0303	0.9129	0.9329	0.9710	0.9984	1.0003
0.10	0.9778	0.0151	0.9517	0.9652	0.9760	0.9897	1.0049
0.15	0.9821	0.0120	0.9665	0.9729	0.9790	0.9909	1.0127
0.20	0.9811	0.0078	0.9679	0.9748	0.9802	0.9879	0.9942
0.25	0.9810	0.0068	0.9688	0.9755	0.9808	0.9880	0.9919
0.30	0.9793	0.0089	0.9648	0.9706	0.9768	0.9886	0.9923
0.35	0.9755	0.0110	0.9567	0.9632	0.9777	0.9838	0.9913
0.40	0.9732	0.0093	0.9560	0.9624	0.9794	0.9815	0.9829
0.45	0.9727	0.0090	0.9561	0.9647	0.9750	0.9792	0.9871
0.50	0.9712	0.0064	0.9589	0.9649	0.9748	0.9762	0.9828
0.55	0.9682	0.0068	0.9558	0.9623	0.9680	0.9736	0.9802
0.60	0.9680	0.0077	0.9536	0.9602	0.9710	0.9754	0.9769
0.65	0.9680	0.0081	0.9512	0.9599	0.9691	0.9746	0.9798
0.70	0.9654	0.0085	0.9503	0.9566	0.9669	0.9732	0.9766
0.75	0.9637	0.0065	0.9485	0.9586	0.9661	0.9695	0.9750
0.80	0.9644	0.0042	0.9510	0.9626	0.9657	0.9671	0.9718
0.85	0.9658	0.0042	0.9531	0.9642	0.9669	0.9679	0.9747
0.90	0.9637	0.0042	0.9563	0.9612	0.9633	0.9651	0.9760
0.95	0.9621	0.0073	0.9538	0.9554	0.9597	0.9702	0.9767
0.99	0.9835	0.0199	0.9654	0.9718	0.9718	0.9860	1.0264
MCO	0.9674	0.0061	0.9548	0.9620	0.9683	0.9733	0.9775

Fuente: Elaboración propia con datos de Bloomberg.

Tabla4.6. Resultados de las estimaciones mensuales de las RCMV fuera de la muestra.

Cuantil	Media	Desviación	Mínimo	25%	50%	75%	Máximo
0.05	0.9703	0.0560	0.8952	0.9168	1.0170	1.0217	1.0219
0.10	0.9700	0.0453	0.8901	0.9323	0.9788	1.0284	1.0305
0.15	0.9389	0.0170	0.8929	0.9317	0.9454	0.9511	0.9623
0.20	0.9483	0.0170	0.9172	0.9404	0.9458	0.9518	0.9895
0.25	0.9516	0.0217	0.9127	0.9348	0.9456	0.9688	0.9925
0.30	0.9618	0.0226	0.9172	0.9381	0.9663	0.9844	0.9979
0.35	0.9679	0.0153	0.9386	0.9640	0.9677	0.9757	0.9987
0.40	0.9699	0.0091	0.9564	0.9604	0.9689	0.9782	0.9870
0.45	0.9716	0.0097	0.9463	0.9667	0.9721	0.9734	0.9966
0.50	0.9714	0.0100	0.9405	0.9659	0.9702	0.9724	0.9977
0.55	0.9697	0.0095	0.9323	0.9620	0.9706	0.9748	0.9890
0.60	0.9681	0.0096	0.9390	0.9631	0.9674	0.9725	0.9901
0.65	0.9704	0.0087	0.9560	0.9650	0.9692	0.9770	0.9853
0.70	0.9751	0.0110	0.9553	0.9644	0.9788	0.9834	0.9992
0.75	0.9718	0.0104	0.9500	0.9657	0.9704	0.9816	0.9894
0.80	0.9723	0.0125	0.9496	0.9663	0.9721	0.9804	1.0000
0.85	0.9744	0.0139	0.9497	0.9627	0.9704	0.9876	0.9994
0.90	0.9724	0.0141	0.9581	0.9622	0.9679	0.9807	1.0036
0.95	0.9767	0.0090	0.9624	0.9699	0.9812	0.9859	0.9859
0.99	1.0283	0.0356	0.9812	0.9833	1.0598	1.0598	1.0598
MCO	0.9703	0.0148	0.9444	0.9568	0.9771	0.9839	0.9930

Fuente: Elaboración propia con datos de Blomberg.

Para el horizonte de cobertura semanal, la desviación estándar de las RCMV es inferior a la del modelo MCO en tres de los cuantiles (0.80, 0.85 y 0.9). Sin embargo, la desviación estándar de las RCMV de MCO es superior a la del método de regresión cuantílica en 12 de 20 cuantiles, esto es, de 0.40 a 0.95. Además, la desviación estándar de las RCMV tiende disminuir en la medida que horizonte de cobertura se incrementa.

Este resultado se atribuye a la reducción del tamaño de la muestra de los datos debido a que varios eventos extremos han sido eliminados del periodo de análisis. Asimismo, los resultados máximos y mínimos son presentados en las Tablas 5, 6 y 7 y ofrecen una comprensión detallada de la variabilidad extrema de las RCMV estimadas fuera de la muestra. Estos valores son fundamentales para evaluar la robustez y la amplitud de las estrategias de cobertura de los modelos MCO y regresión cuantílica. Además, se incluyen los percentiles 25%, 50% y 75% para proporcionar una visión más completa de la distribución de las RCMV. Estos percentiles no solo permiten evaluar los valores extremos, sino también ofrecen ideas clave sobre la variabilidad en las recomendaciones de cobertura en diferentes niveles de riesgo.

#### **4.4 Evaluación de la efectividad de la cobertura dentro de la muestra**

En la práctica, los inversionistas individuales e institucionales no solo toman posiciones cortas o largas en los mercados de futuros para mitigar la exposición al riesgo de precios, sino también evalúan la calidad de sus coberturas, es decir, el desempeño de los modelos estimados que permite reducir el riesgo en el portafolio de cobertura. Para la evaluación de la efectividad de la cobertura, este estudio utiliza los índices eficientes de reducción de la varianza y valor en riesgo (ICE) para determinar el desempeño de los modelos de regresión cuantílica y MCO en la reducción del riesgo del portafolio de cobertura.

La Tabla 4.7 presenta los resultados del ICE basado en la reducción de la varianza dentro de la muestra para los 3 horizontes de cobertura. De acuerdo con el ICE, el modelo MCO exhibe un mejor desempeño en comparación con el modelo de regresión cuantílica en la mayoría de los cuantiles en el horizonte de cobertura diario, excepto para el cuantil 0.99. En este caso, ambos modelos presentan un valor del ICE del 95.3404%. Sin embargo, el modelo MCO se ve superado por el modelo de regresión cuantílica en la mayoría de los

cuantiles analizados para el horizonte de cobertura semanal, particularmente en los cuantiles centrales de la distribución condicional, donde el cuantil 0.50 proporciona un valor ICE de 98.0588%.

Asimismo, el desempeño del modelo de regresión cuantílica presenta superior desempeño en la mayoría de los cuantiles en comparación con el modelo MCO para el horizonte de cobertura mensual. De los 20 cuantiles analizados, solo 3 tienen un ICE menor al del modelo MCO. De hecho, la efectividad de la cobertura para reducir el riesgo es alcanzada en los cuantiles 0.30 y 0.35 con un valor de **98.4113%**. Además, los resultados muestran que en la medida que el horizonte de cobertura se incrementa, el desempeño de la cobertura mejora, aunque no converge a 1. La razón detrás de este comportamiento puede estar relacionada con la posible demora en la adaptación del precio de contado a cambios en el precio fundamental, la cual está relacionada con la respuesta más rápida de los precios de los futuros a estas variaciones (Shrestha et al., 2018).

Por otra parte, otra medida alternativa para la evaluación de la efectividad de la cobertura es la metodología VaR. En la Tabla 4.8 se reportan los resultados del ICE basado en la medida VaR. La evidencia empírica muestra que el desempeño del modelo MCO es superior para reducir el riesgo en el portafolio de cobertura en comparación con el modelo de regresión cuantílica en la mayoría de los cuantiles para el horizonte de cobertura diario con un  $ICE_{VaR}$  de **78.5338%**. Este hecho se atribuye a que las estimaciones de las RCMV son menos conservadoras y volátiles a través del tiempo. No obstante, el desempeño del modelo de cobertura cuantílica es superior al modelo MCO para el horizonte de cobertura semanal en todos los cuantiles, especialmente para el cuantil 0.50 de la distribución condicional con un valor  $ICE_{VaR}$  de **86.2792%**.

Tabla 4.7. Resultados del índice eficiente de reducción de varianza para los diferentes cuantiles.

Cuantil	Diario	Semanal	Mensual
0.05	95.3321%	98.0561%	98.0336%
0.10	95.3379%	97.9637%	98.0475%
0.15	95.3369%	98.0409%	98.4079%
0.20	95.3378%	98.0380%	98.3683%
0.25	95.3392%	98.0361%	98.3508%
0.30	95.3370%	98.0545%	<b>98.4113%</b>
0.35	95.3350%	98.0580%	98.4055%
0.40	95.3400%	98.0568%	98.4108%
0.45	95.3377%	98.0579%	98.4029%
0.50	95.3344%	<b>98.0588%</b>	98.3848%
0.55	95.3266%	98.0579%	98.3866%
0.60	95.3274%	98.0572%	98.3928%
0.65	95.3297%	98.0551%	98.3911%
0.70	95.3362%	98.0478%	98.3862%
0.75	95.3391%	98.0536%	98.3968%
0.80	95.3341%	98.0545%	98.3895%
0.85	95.3276%	98.0550%	98.2490%
0.90	95.3363%	98.0575%	98.3906%
0.95	95.3008%	98.0581%	98.3916%
0.99	<b>95.3404%</b>	97.7169%	98.3161%
MCO	<b>95.3404%</b>	97.7169%	98.3161%

Fuente: Elaboración propia con datos de Bloomberg.

Tabla 4.8. Resultados del índice eficiente del VaR para los diferentes cuantiles.

Cuantil	Diario	Semanal	Mensual
0.05	78.5082%	86.2752%	86.3251%
0.10	78.5298%	85.9801%	86.3766%
0.15	78.5279%	86.2306%	87.8486%
0.20	78.5295%	86.2213%	87.6550%
0.25	78.5319%	86.2154%	87.5775%
0.30	78.5280%	86.2708%	87.8767%
0.35	78.5243%	86.2728%	87.8765%
0.40	78.5332%	86.2667%	<b>87.8818%</b>
0.45	78.5294%	86.2722%	87.8707%
0.50	78.5230%	<b>86.2792%</b>	87.8211%
0.55	78.5072%	86.2719%	87.8263%
0.60	78.5088%	86.2683%	87.8444%
0.65	78.5135%	86.2585%	87.8394%
0.70	78.5265%	86.2278%	87.8253%
0.75	78.5318%	86.2521%	87.8554%
0.80	78.5225%	86.2558%	87.8350%
0.85	78.5092%	86.2583%	87.3781%
0.90	78.5266%	86.2700%	87.8380%
0.95	78.4522%	86.2733%	87.8409%
0.99	<b>78.5338%</b>	85.1806%	87.6010%
<b>MCO</b>	<b>78.5338%</b>	85.1800%	87.6000%

Fuente: Elaboración propia con datos de Bloomberg.

Finalmente, el modelo de regresión cuantílica es más eficiente que el modelo MCO en 16 de los 20 cuantiles de la distribución condicional para el horizonte de cobertura mensual. De hecho, el  $ICE_{VaR}$  alcanza la efectividad de la cobertura más alta para reducir el riesgo en el portafolio de cobertura en el cuantil 0.40 con un valor de **87.8818%**. Al igual que en el ICE basado en la reducción de la varianza, el  $ICE_{VaR}$  converge al 100% de efectividad conforme el horizonte de cobertura se incrementa, aunque más lentamente que el índice de reducción de varianza.

#### **4.5 Análisis de la efectividad de la cobertura fuera de la muestra**

Los índices eficientes de cobertura son analizados en esta sección utilizando 1258 RCMV para evaluar el desempeño fuera de la muestra de los modelos MCO y regresión cuantílica. En el procedimiento de estimación se emplea la misma técnica de ventana móvil que coadyuva a la actualización de las estimaciones de los 2 índices de eficiencia. El tamaño de la muestra fija es de 251 observaciones que corresponde del 2 de enero al 31 de diciembre de 2018. Las últimas 1,007 observaciones, que corresponden al periodo del 2 de enero de 2019 al 30 de diciembre de 2022, son usadas para el análisis fuera de la muestra. La Figura 4.7 proporciona una representación visual del comportamiento del ICE basado en la medida de reducción de varianza para el horizonte de cobertura diario. Los valores del ICE fluctúan entre los valores 89.4339% y 94.7588%. Asimismo, el índice de eficiencia de cobertura más bajo se registró en diciembre de 2019, mientras que el valor más alto se alcanzó en junio de 2021.

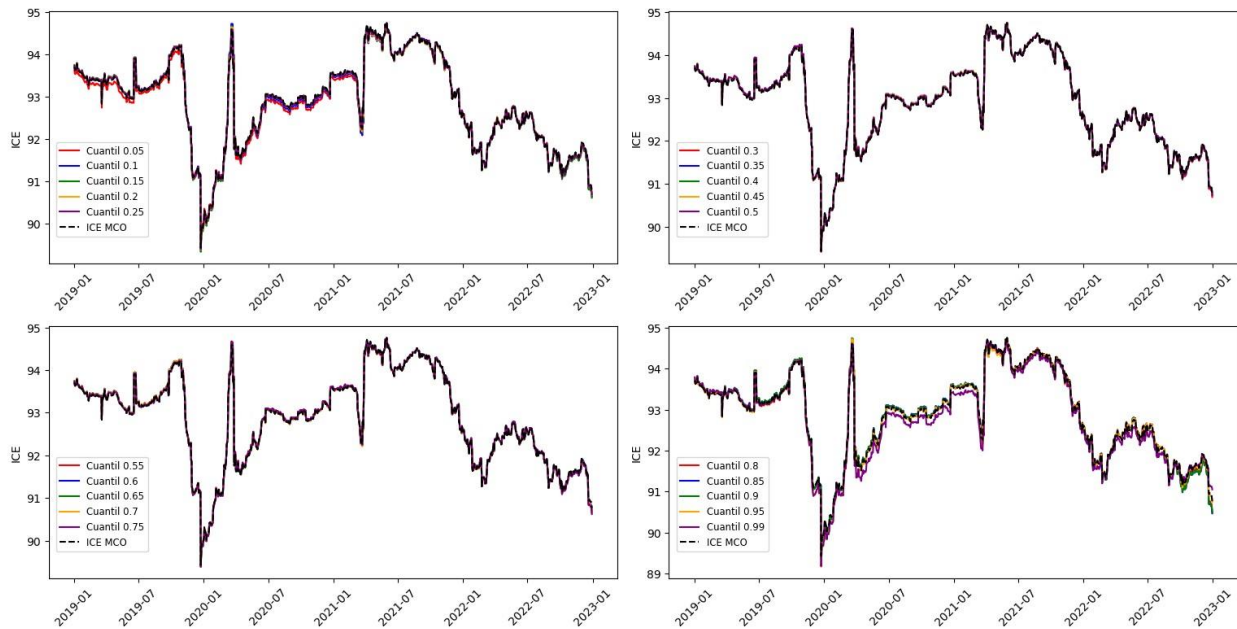


Figura 4.7. Índices eficientes de cobertura diarios fuera de la muestra de MCO y regresión cuantílica.

Fuente: Elaboración propia con datos de Bloomberg en Python.

Los resultados del ICE proporcionan información clave sobre el desempeño de los modelos de cobertura estimados para reducir la varianza en el portafolio de cobertura. De esta manera, los gráficos muestran que el comportamiento de los índices de eficiencia de la cobertura es muy similar a través del tiempo en los cuantiles intermedios de la distribución condicional, mientras que su comportamiento es ligeramente más volátil en los cuantiles extremos. Por otra parte, el valor promedio del ICE fuera de la muestra es del 92.868% en los 20 cuantiles analizados, lo que implica el desempeño del modelo de regresión cuantílica reduce la varianza en el portafolio de cobertura por arriba del 90%. Al observar los cuantiles centrales de 0.30 a 0.75, el desempeño del modelo de regresión cuantílica es superior al desempeño del modelo MCO debido a que su valor promedio se encuentra por debajo del 92.8742% aproximadamente. Por su parte, la máxima reducción de la varianza en el portafolio de cobertura es alcanzada en el cuantil 0.35 con un valor promedio del 92.88971%, mientras que el valor promedio más bajo para reducir la varianza ocurre en el cuantil 0.99 con 92.7892% aproximadamente.



En general, los resultados fuera de la muestra indican que el desempeño del modelo MCO es superior al del modelo de regresión cuantílica para el horizonte fuera de la muestra diario, particularmente en el periodo de análisis del 15 de septiembre al 30 de diciembre del 2022. Aunque el modelo de regresión cuantílica mejora las estrategias de cobertura para reducir la varianza en el portafolio de cobertura en el periodo del 2 de enero al 8 de noviembre del 2019. Igualmente, es importante destacar que el modelo de regresión cuantílica proporciona estrategias de cobertura más efectivas que la aproximación de MCO en el periodo del 10 al 27 de marzo de 2020 cuando la crisis sanitaria de Covid-19 se agravó en todo el mundo. En este periodo de alta volatilidad, el índice eficiente de reducción de varianza alcanzó valores entre 91.6267% y 94.7424%, lo que implica que el modelo de regresión tiene la capacidad para capturar los eventos extremos generados por la pandemia de Covid-19.

Por otra parte, los valores del ICE fuera de la muestra del modelo MCO son menos volátiles debido a que su desviación estándar es más con respecto a la del modelo de regresión cuantílica en 19 de los 20 cuantiles. Esto se debe a que el comportamiento de los ICE del modelo MCO es constante a través del tiempo, es decir, el modelo de regresión cuantílica es más robusto para capturar los choques de mercado en periodos de extrema volatilidad. Finalmente, las variaciones en los ICE son más notables en los cuantiles de 0.90 y 0.99, debido al hecho de que oscilan en un rango más amplio, entre 89.3411%-94.7424% y 89.1825%-94.7121%, respectivamente.

La Figura 4.8 muestra el comportamiento de los ICE fuera de la muestra para el horizonte de cobertura semanal. Los resultados confirman que el desempeño del modelo de regresión cuantílica reduce la varianza del portafolio de cobertura en un 96.8365% en promedio para todos los cuantiles. Este resultado es más notable entre los cuantiles 0.75-0.99 de la distribución condicional, puesto que superan al valor promedio del ICE del modelo MCO. Asimismo, la efectividad de la cobertura cuantílica alcanzó el valor máximo de 98.6390% en marzo del 2021, mientras que el valor mínimo fue de 93.6566% en marzo de 2022. De acuerdo con los valores del ICE, el desempeño del modelo de regresión cuantílica proporciona efectivas estrategias de cobertura en comparación con el modelo MCO en periodos de extrema volatilidad, particularmente en el periodo del 4 de octubre de 2019 al 26 de febrero de 2021. Por el contrario, el modelo MCO mejora la efectividad

de la cobertura para reducir la varianza en el portafolio de cobertura a partir del periodo del 16 de julio de 2021 al 30 de diciembre de 2022.

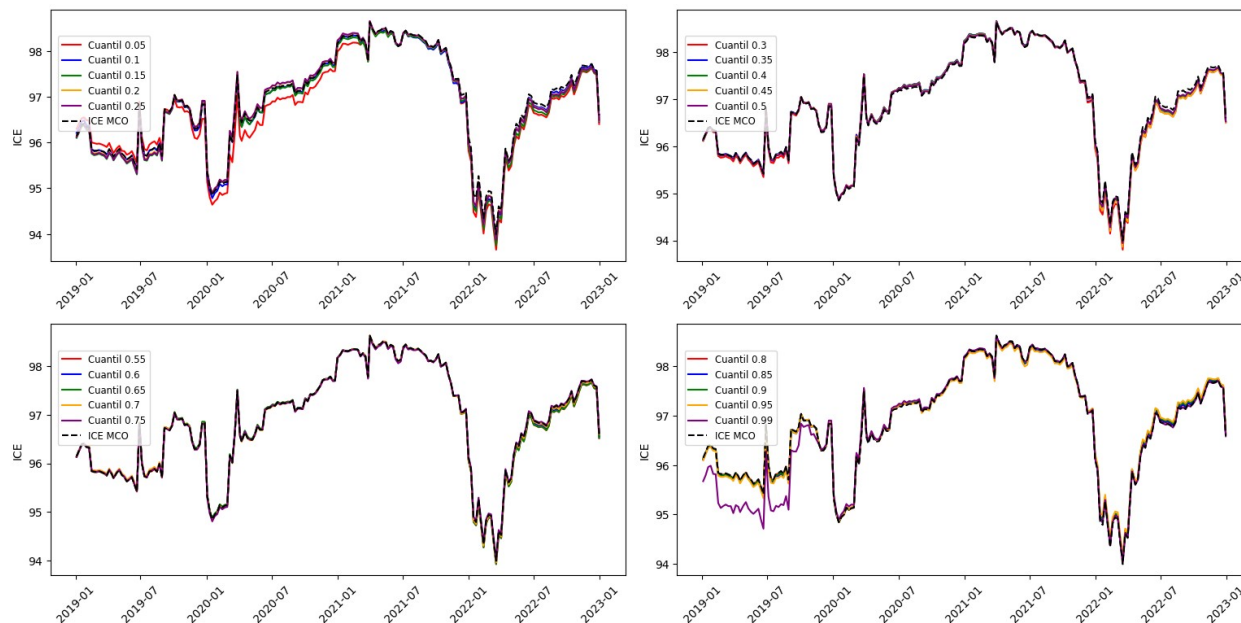


Figura 4.8. Índices eficientes de cobertura fuera de la muestra semanales con MCO y regresión cuantílica.

Fuente: Elaboración propia con datos de Bloomberg en Python.

Por su parte, la Figura 4.9 ilustra el comportamiento de la efectividad de la cobertura fuera de la muestra a través de los ICE mensuales. El análisis de las gráficas muestra que la efectividad de la cobertura desciende notablemente en febrero de 2020 (92.92437% para el cuantil 0.30) en ambos modelos de cobertura y mayoría de los cuantiles de la distribución condicional, mientras que las estrategias de cobertura alcanzan su máxima efectividad en diciembre de 2022, en particular el cuantil 0.90 con un valor de 99.4447%. Otro resultado importante es que el desempeño del modelo de regresión cuantílica mejora la cobertura con futuros en un 97.4168% en promedio para todos los cuantiles, lo que confirma de que la efectividad de la cobertura se incrementa en la medida que el horizonte de cobertura se incrementa. Este hecho se atribuye a que un horizonte de cobertura más largo reduce el tamaño de la muestra, lo que proporciona menor cantidad de información para la estimación de las razones de cobertura. La literatura ha demostrado que el problema de reducción del tamaño de la muestra mejore la eficiencia de la cobertura de

los modelos para reducir la varianza en el portafolio de cobertura bajo diferentes condiciones del mercado.




Figura 4. 9. Índices eficientes de cobertura mensuales fuera de la muestra con MCO y regresión cuantílica.

Fuente: Elaboración propia con datos de Bloomberg en Python.

En este contexto, el desempeño fuera de la muestra del modelo de regresión cuantílica es notablemente superior respecto al del modelo MCO en los cuantiles del 0.35 al 0.95, excepto para el cuantil 0.85 de la distribución condicional de los rendimientos del índice accionario S&P/BVM IPC. Por su parte, el modelo MCO tiene la capacidad para reducir la varianza fuera de la muestra en el portafolio de cobertura en un 97.4677% en promedio. Sin embargo, el modelo de regresión cuantílica mejora la calidad de la cobertura con futuros con valores promedios de 97.54698%, 97.55647% y 97.58363% para los cuantiles del 0.55, 0.60 y 0.75, respectivamente. No obstante, el modelo de cobertura cuantílica presenta su peor desempeño para reducir la varianza en el portafolio de cobertura en los cuantiles 0.05 y 0.30 con valores promedios de 97.1210% y 97.3696%. Otro resultado importante de señalar es que el desempeño fuera de la muestra del modelo es superior en gran medida al modelo regresión cuantílica en el periodo del 31 de enero de 2019 al 31 de marzo de 2020. Mientras que el modelo de cobertura cuantílica proporciona

excelentes estrategias de cobertura para reducir la exposición al riesgo de precios en el periodo de alta volatilidad del 30 de abril de 2020 al 30 de julio de 2021.

Por su parte, las figuras 4.10, 4.11 y 4.12 ilustran el comportamiento del desempeño fuera de la muestra de los modelos de cobertura a través de los  $ICE_{VaR}$  para los horizontes de cobertura diario, semanal y mensual, respectivamente. Para el horizonte de cobertura diario, los modelos de cobertura estimados alcanzan a reducir el VaR en el portafolio cobertura desde 67.9806% hasta 78.0355% para todos los cuantiles de la distribución condicional. En este contexto, el desempeño del modelo MCO mejora la efectividad de la cobertura fuera de la muestra en un 85.0573% en promedio con respecto al del modelo de regresión cuantílica en 7 de los 20 cuantiles de la distribución condicional, debido a que la máxima efectividad de la cobertura es alcanzada en los cuantiles 0.35 y 0.55 con valores promedios de 73.4394% y 73.43706%, respectivamente.

Otro importante resultado es que el desempeño de los modelos MCO y regresión cuantílica es mixto en diferentes periodos de estudio. Por ejemplo, el modelo de cobertura cuantílica proporciona mejores estrategias de cobertura fuera de la muestra en los periodos de análisis del 2 de enero al 5 de julio del 2019 y 19 de mayo del 2021 al 23 de febrero del 2022. Aunque es importante resaltar que las coberturas cuantílicas son superiores a las coberturas tradicionales en 18 de los 20 cuantiles para el periodo del 10 al 27 de marzo del 2020. Este hecho es atribuido a que el modelo de regresión cuantílica no es sensible a la presencia de eventos extremos generados por la creciente volatilidad. Por el contrario, la efectividad de la cobertura del modelo MCO es superior a las coberturas cuantílicas en los periodos del 29 noviembre del 2019 al 2 de marzo del 2020 y 29 de marzo al 18 de mayo del 2021.




Figura 4.10. Índices diarios de reducción del VaR fuera de la muestra.  
Fuente: Elaboración propia con datos de Bloomberg en Python.




Figura 4.11. Índices semanales de reducción del VaR fuera de la muestra.  
Fuente: Elaboración propia con datos de Bloomberg en Python.

Para el horizonte de cobertura semanal, los modelos de cobertura cuantílica y MCO alcanzan a reducir el riesgo en el portafolio de cobertura en un rango de 76.0839% a 88.8756% en términos generales. Sin embargo, el modelo MCO presenta mejor

desempeño que el modelo de regresión cuantílica en un 81.7438% en promedio con respecto a 14 cuantiles, esto es, de 0.10 a 0.70 y 0.99. Aunque las coberturas cuantílicas son superiores a las coberturas MCO para reducir el riesgo fuera de la muestra en los cuantiles del 0.05 y 0.95 con valores promedios del  $ICE_{VaR}$  de 82.22366% y 81.98216%, respectivamente. En un análisis más profundo, los resultados del  $ICE_{VaR}$  confirman que el modelo de cobertura cuantílica proporciona mejores estrategias para reducir el riesgo en las posiciones de contado en el periodo fuera de la muestra del 18 de octubre de 2019 al 13 de noviembre de 2020. Por el contrario, las coberturas de MCO son notablemente superiores a las coberturas cuantílicas en el periodo de análisis fuera de la muestra del 3 de diciembre de 2021 al 30 diciembre de 2022.




Figura 4.12. Índices mensuales de reducción del VaR fuera de la muestra.  
Fuente: Elaboración propia con datos de Bloomberg en Python.

Para el horizonte de cobertura mensual, las estrategias de cobertura cuantílicas y MCO reducen la exposición al riesgo en un rango de valores entre 73.7631% y 92.7718%. Al igual que el índice de eficiencia de reducción de varianza, la efectividad de la cobertura se incrementa en los horizontes de tiempo más largos, aunque a un ritmo menor. Asimismo, los resultados de los  $ICE_{VaR}$  promedios señalan que el modelo de regresión cuantílica presenta mejor desempeño que el modelo MCO para reducir el riesgo en el portafolio de cobertura para los cuantiles intermedios de la distribución condicional, especialmente para

el cuantil 0.75 con valor promedio de 85.1843% contra 85.0573% de MCO. Otro hallazgo importante de destacar es que el modelo de regresión cuantílica proporciona excelentes coberturas con respecto al modelo MCO en los periodos de alta volatilidad, esto es, en el periodo del 30 de abril de 2020 al 31 de marzo de 2021.

En contraste, las coberturas de MCO son notablemente mejores a las coberturas cuantílicas para reducir la exposición al riesgo de precios en el periodo del 31 de enero de 2019 al 31 de marzo de 2020. Finalmente, otro hallazgo observado en el análisis fuera de la muestra es que los resultados de los  $ICE_{VaR}$  convergen al valor del 100% más lentamente que los valores del índice de eficiencia de reducción de varianza. Este hecho se atribuye a que el índice de eficiencia de reducción de varianza es una medida menos robusta para capturar los eventos extremos debido a que solo utiliza los primeros dos momentos de la distribución para evaluar el desempeño de los modelos de cobertura a diferencia de la medida VaR.

## Capítulo 5. Conclusiones

Este trabajo propone el modelo de regresión cuantílica para estimar las RCMV y evaluar el desempeño de los modelos de cobertura cuantílica y MCO para reducir la varianza del portafolio de cobertura utilizando información de los rendimientos de los precios diarios, semanales y mensuales del índice accionario S&P/BMV IPC y sus contratos de futuros para el periodo del 2 de enero de 2013 al 30 de diciembre de 2022. La estimación de las RCMV y evaluación del desempeño de los modelos de cobertura se lleva a cabo en dos periodos utilizando dos criterios de evaluación: índice eficiente de reducción de varianza y VaR al 5%. Para el análisis dentro de la muestra se utiliza el periodo 2 de enero de 2013 al 29 de diciembre de 2017, mientras que análisis fuera de la muestra corresponde al periodo del 3 de enero de 2018 al 31 de diciembre de 2022.

De acuerdo con los resultados dentro de la muestra (Tabla 4.3), las RCMV estimadas por el modelo de regresión cuantílica son más conservadoras y volátiles que las estimadas por el modelo MCO para los tres horizontes de cobertura, lo que confirma que el modelo de cobertura cuantílica tiene mayor capacidad para capturar los diferentes niveles de asimetría y eventos extremos observados en las series financieras. Asimismo, las estimaciones fuera de la muestra de las RCMV cuantílicas son más altas que las del modelo MCO en la mayoría de los cuantiles y para los 3 horizontes de cobertura. Esta superioridad se debe a la capacidad de la regresión cuantílica para capturar cambios en la volatilidad como consecuencia de la presencia de valores atípicos.

Los resultados tienen importantes implicaciones financieras para los inversionistas institucionales que buscan estrategias de cobertura óptimas, y que se puedan ajustar apropiadamente en los diferentes escenarios del mercado. En cuanto a la evaluación de la calidad de la cobertura, la evidencia empírica es mixta debido a que el desempeño dentro de la muestra del modelo MCO es superior para reducir la varianza y VaR en el portafolio de cobertura que el modelo de regresión cuantílica en la mayoría de los cuantiles de la distribución condicional. Para los horizontes de cobertura semanal y mensual, el modelo de regresión cuantílica presenta el mejor desempeño para mejorar la cobertura de



la posición abierta en el índice accionario de la Bolsa Mexicana de Valores en todos los cuantiles para los datos semanales y en 16 cuantiles de los rendimientos mensuales.

Los hallazgos de la evaluación de la cobertura son mixtos para los diferentes horizontes de tiempo. En general, el modelo MCO proporciona excelentes estrategias de cobertura para los periodos normales de mercado, mientras el modelo de regresión cuantílica mejora la efectividad de la cobertura en los periodos de extrema volatilidad. Asimismo, los resultados obtenidos en este estudio tienen importantes implicaciones económicas y financieras para los participantes de los mercados financieros y los administradores de riesgos. Por ejemplo, los administradores de riesgos podrán reducir su exposición al riesgo a costos relativamente bajos cuando participen en mercados financieros altamente volátiles. Por su parte, los reguladores pueden reducir el régimen de inversión de las SIFORES debido a que cuenta con excelentes mecanismos de cobertura para asumir mayores riesgos en los mercados de capitales.

Finalmente, los hallazgos confirman el potencial del modelo de regresión cuantílica para estimar las RCMV dinámicas y mejorar la efectividad de la cobertura con futuros financieros. Sin embargo, una investigación a futuro sería estudiar el comportamiento de las estrategias de coberturas cuantílicas a través de diferentes cambios de régimen en la volatilidad, incluso comparar los resultados entre mercados financieros de países desarrollados y emergentes, todo esto con el fin de evaluar de manera más completa la capacidad predictiva del modelo de regresión cuantílica en diferentes escenarios económicos, mejorando así su aplicabilidad práctica.

## Bibliografía

- Bell, D. y Krasker, W. (1986). Estimating hedge ratios, *Financial Management* 15, 34–39.
- Benninga, S., Eldor, R. y Zilcha, I. (1983). Optimal Hedging in the Futures market under price uncertainty, *Economic Letters*, 13, 141-145.
- Bertsimas, D. y Tsitsiklis, J. N. (2003). Optimization fundamentals, *Pearson Education*.
- Bhaduri, N. y Durai, S. (2008). Optimal hedge ratio and hedging effectiveness of stock index futures: evidence from India, *Macroeconomics and Finance in Emerging Market Economies*, 1, 121–134.
- Bodie, Z., Kane, A., y Marcus, A. J. (2019). Investments (12.<sup>a</sup> ed.). *McGraw Hill*, 24.
- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroscedasticity, *Journal of Econometrics*, 31, 307-327.
- Bonga, L. y Umoetok, E. (2016). The effectiveness of index futures hedging in emerging markets during the crisis period of 2008-2010: Evidence from South Africa, *Applied Economics*, 48, 3999-4018.
- Brooks, C., Henry, O.T. y Persaud, G. (2002). The Effects of Asymmetries on Optimal Hedge Ratios, *Journal of Business*, 75, 333-352.
- Buyukkara, G., Kucukozmen, C. C., y Uysal, E. T. (2021). Optimal hedge ratios and hedging effectiveness: An analysis of the Turkish futures market, *Borsa Istanbul Review*, forthcoming.
- Carollo, M.C. (2012). Regresión lineal simple. *Departamento de Estadística e Investigación Operativa USC*, Santiago de Compostela.
- Castellino, M. (1990). Minimum-Variance Hedging with Futures Re-visited, *Journal of Portfolio Management*, 16, 74-80.
- Chakraborty, A. y Barkoulas, J.T. (1999), Dynamic Futures Hedging in Currency Markets, *The European Journal of Finance*, 5, 299-314.

- Chen, R. R., Leistikov, D., y Wang, A. (2020). Futures minimum variance hedge ratio determination: An ex-ante analysis, *The North American Journal of Economics and Finance*, 54.
- Chernozhukov, V. y Umantsev, L. (2001). Conditional value-at-risk: Aspects of modeling and estimation, *Empirical Economics*. 26, 271–292.
- Chou, W. L., Denis, K., y Lee, C. (1996). Hedging with the Nikkei index futures: The conventional model versus the error correction model, *The Quarterly Review of Economics and Finance*, 36, 495-505.
- Choudhry, T. (2004). The hedging effectiveness of constant and time-varying hedge ratios using three Pacific Basin stock futures, *International Review of Economics and Finance*, 13, 371–385.
- Cotter, J. y J. Hanly (2006). Reevaluating hedging performance, *The Journal of Futures Market*, 26, 677-702.
- De Jesús Gutiérrez, R. (2016). Estrategias dinámicas de cobertura cruzada eficiente para el mercado del petróleo mexicano: evidencia de dos modelos GARCH multivariados con término de corrección de error, *Economía Teoría y Práctica*, 44.
- De Jesús Gutiérrez, R., Pacheco, C. B., y Gutiérrez, L. C. (2021). Razones de cobertura con futuros de los índices accionarios de Brasil y México, *Investigación Administrativa*, 50-2, 1-23.
- Ederington, L. H. (1979). The Hedging Performance of the New Futures Markets. *The Journal Of Finance*, 34, 157-170.
- Engle, R.F. y Granger C.W.J. (1987). Cointegration and Error Correction: Representation, Estimation and Testing, *Econometrica*, 55, 251-276.
- Fallon, W. (1996). Calculating Value at Risk, *Wharton Financial Institutions Center Working Paper Series*, 96-49.
- Fernández, J. (2022). ¿Qué es y cómo se calcula el IPC en México? *Rankia*.

- Figlewski, S. (1984), Hedging Performance and Basis Risk in Stock Index Futures, *Journal of Finance*, 39, 657-669.
- Figlewski, S. (1985). Hedging with Stock Index Futures: Theory and Application in a New Market, *Journal of Futures Markets*, 5, 183-189.
- Floros, C. y D. V. Vougas (2004). Hedge ratios in Greek stock index futures market, *Applied Financial Economics*, 14, 1125-36.
- Geraghty, M. A. (2023). Estadística inferencial y probabilidad: Un enfoque holístico, *De Anza College*.
- Ghosh, A. (1993). Hedging with stock index futures: Estimation and forecasting with error correction model, *Journal of Futures Markets*, 13, 743-752.
- Gujarati, D. N. y D. Porter (2003). Basic Econometrics, *McGraw-Hill*, International Edition.
- Hanke, J. y Wichern, D. (2006). Pronósticos en los negocios. *Editorial Pearson*. México.
- Hasan, M. Choudhry, T. y Zhang, Y. (2020). An econometric investigation of hedging performance of stock index futures in Korea: Dynamic versus static hedging, *International Journal of Banking, Accounting and Finance*, 11, 227–253.
- Herbst, A., Kare, D., y J. Marshall, (1989). A time varying, convergence adjusted, minimum risk futures hedge ratio, *Advances in Futures and Options Research* 6, 137–155.
- Hill, J. y Schneeweis, T. (1981). A Note on the Hedging effectiveness of Foreign Currency Futures, *The Journal of Financial Research*, 1, 659-664.
- Holmes, P. (1995). Ex ante Hedge Ratios and the Hedging Effectiveness of the FTSE-100 Stock Index Futures Contracts, *Applied Economic Letters*, 2, 56-59.
- Johnson, L. L. (1960). The Theory of Hedging and Speculation in Commodity Futures, *Review of Economic Studies*, 27, 139-151.
- Junkus, C.J. y Lee, C. (1985), The use of Three Stock Index Futures in Hedging Decisions, *Journal of Futures Markets*, 5, 201-222.

- Just, M. y Echaust, K. (2020). Stock market returns, volatility, correlation and liquidity during the COVID-19 crisis: Evidence from the Markov switching approach, *Financial Research Letters*, 37, 1-8.
- Kaur, M. y Gupta, K. (2019). Estimating hedging effectiveness using variance reduction and risk-return approaches: Evidence from National stock exchange of India, *Copernican Journal of Finance y Accounting*, 8, 149-169.
- Koenker, R., y G. Bassett. (1978). Regression quantiles, *Econometrica*, 46, 33–50.
- Koutmos, G. y A. Pericli (1998). Dynamic hedging of commercial paper with T-bills futures. *The Journal of Futures Markets*, 18, 925-38.
- Ku, Y. H., Chen, H. y Chen, K. (2007). On the application of dynamic conditional correlation model in the estimating optimal time-varying hedge ratios, *Applied Economics Letters*, 14, 503-509.
- Lai, Y. (2018). Dynamic hedging with futures: a copula-based GARCH model with high-frequency data, *Review of Derivatives Research*.
- Lee, H. C. y Chien, C. Y. (2010). Hedging performance and stock market liquidity: Evidence from the Taiwan futures market, *Asia-Pacific Journal of Financial Studies*, 39, 396–415.
- Lien, D. (1996). The Effect of the Cointegration Relationship on Futures Hedging, *Journal of Futures Markets*, 16, 773-780.
- Lien, D. y Lou, X. (1994). Multiperiod hedging in the presence of conditional heteroskedasticity, *The Journal of Futures Markets*, 14, 927- 955.
- Lien, D. y Luo, X. (1993). Estimating Multiperiod Hedge Ratios in Cointegrated Markets, *Journal of Futures Markets*, 13, 909-920.
- Lien, D. y Tse, Y.K. (1999). Fractional Cointegration and Futures Hedging, *Journal of Futures Markets*, 19,457-474.
- Lien, D., Shrestha, K. y Wu, J. (2015). Quantile Estimation of Optimal Hedge Ratio, *Journal of Futures Markets*, 36, 194-214.

- Lien, D., Tse, Y.K. y Tsui, A.K.C. (2002), Evaluating the Hedging performance of the Constant-Correlation GARCH model, *Applied Financial Economics*, 12, 791- 798.
- Lien, D., y Mei, Z. (2008). A survey of emerging derivatives markets. *Emerging Markets Finance and Trade*, 44(2), 39-69.
- Lyócsa, S., Baumöhl, E., Výrost, T. y Molnár, P. (2020). Fear of the coronavirus and the stock markets, *Financial Research Letters*, 36, 1-7.
- Lypny, G. y Powalla, M. (1998). The Hedging effectiveness of DAX Futures, *The European Journal of Finance*, 4, 345-355.
- Mariño, U. D. y Melo, V. L. F. (2016). Regresión cuantílica dinámica para la medición del valor en riesgo: una aplicación a datos colombianos, *Cuadernos de Economía*, 38, 23-50.
- Markowitz, H. (1952). Portfolio Selection, *Journal of Finance*, 7, 77-91.
- Miffre, J. (2004). Conditional OLS Minimum Variance Hedge Ratios, *Journal of Futures Markets*, 24, 945–64.
- Moon, G., Yu, W. y Hong, C. (2009). Dynamic hedging performance with the evaluation of multivariate GARCH models: Evidence from KOSTAR index futures, *Applied Economics Letters*, 16, 913-919.
- Moosa, I.A. (2003). The Sensitivity of the Optimal Hedge Ratio to Model Specification, *Finance Letters*, 1,15-20.
- Myers, R. J. (1991). Estimating Time-Varying Hedge Ratios on Futures Markets, *Journal of Futures Markets*, 11, 39-53.
- Myers, R. J. y Thompson, S.R. (1989). Generalized Optimal Hedge Ratio Estimation, *American Journal of Agricultural Economics*, 71, 858-867.
- Olgun, O. y Yetkiner, I. H. (2011). Determination optimal hedging strategy for index futures: Evidence from Turkey. *Emerging Markets Finance and Trade*, 47, 68-79.
- Park, H. y Bera, A. (1987). Interest rate volatility, basis, and heteroscedasticity in hedging mortgages, *American Real Estate and Urban Economics Association*, 15, 79–97.

- Park, S. Y. y Jei, S. Y. (2010). Estimation and hedging effectiveness of time-varying hedge ratio: flexible bivariate GARCH approaches, *Journal of Futures Markets*, 30, 71-79.
- Park, T.H. y Switzer, L.N. (1995), Bivariate GARCH Estimation of the Optimal Hedge Ratios for Stock Index Futures: A Note, *Journal of Futures Markets*, 15, 61-67.
- Ruiz, Á. C. (2019). Regresión cuantílica para la cuantificación del riesgo, *Universidad de Barcelona*.
- Shrestha, K., Subramaniam, R., Peranginangin, Y. y Philip, S. S. S. (2018). Quantile hedge ratio for energy markets. *Energy Economics*, 71, 253-272.
- Smales, L.A. (2021). Investor attention and global market returns during the COVID-19 crisis, *International Review of Financial Analysis*, 73, 1-14.
- Spencer, S. E. F., Bredin, D. y Conlon, T. (2018). Energy and agricultural commodities revealed through hedging characteristics: Evidence from developing and mature markets, *Journal of Commodity Markets*, 9, 1-20.
- Statista. (2021). Mercados Intercambio de derivados: ranking según contratos 2019, *Statista*.
- Stein, J.L. (1961). The simultaneous Determinations of Spot and Futures Prices, *American Economic Review*, 51, 1012-1025.
- Weisberg, S. (2005). Applied Linear Regression, *John Wiley y Sons*, 3.
- Witt, H. J., Schroeder, T.C. y Hayenga, M. L. (1987). Comparison of Analytical Approaches for Estimating Hedge Ratios for Agricultural Commodities, *Journal of Futures Markets*, 7, 135-146.
- Yang, W. (2001), M-GARCH Hedge Ratios and Hedging Effectiveness in Australian Futures Markets, *School of Finance and Business Economics*, Edith Cowan University.
- Yang, W. y Allen D. E. (2005). Multivariate GARCH hedge ratios and hedging effectiveness in Australian futures markets, *Accounting and Finance*, 45, 301-321.
- Yao, Z. y Wu, H. (2012). Financial engineering estimation of minimum risk hedge ratios. *Procedia Systems Engineering*, 3, 187-193.

Zhou, J. (2016). Hedging performance of REIT index futures: A comparison of alternative hedge ratio estimation methods, *Economic Modeling*, 52, 690-698.

Zurita, L. S. (2002). Sobre la cobertura de mínima varianza con futuros, Chile: *Universidad Adolfo Ibáñez*.