

2017


EVALUAR VALIDEZ DE LOS MODELOS PARAMÉTRICOS, SEMIPARAMÉTRICOS Y NO PARAMÉTRICOS DEL VALOR EN RIESGO (VAR) , REALIZANDO UN BACKTESTING PARA EL MERCADO DE COMMODITIES

FLORES ASTUDILLO, MARIO JAVIER

<http://hdl.handle.net/11673/23534>

Repositorio Digital USM, UNIVERSIDAD TECNICA FEDERICO SANTA MARIA

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INDUSTRIAS
VALPARAISO- CHILE



**EVALUAR VALIDEZ DE LOS MODELOS PARAMÉTRICOS,
SEMIPARAMÉTRICOS Y NO PARAMÉTRICOS DEL VALOR EN
RIESGO (VAR) , REALIZANDO UN BACKTESTING PARA EL
MERCADO DE COMMODITIES**

MARIO JAVIER FLORES ASTUDILLO

MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL INDUSTRIAL

PROFESOR GUÍA : SR. WERNER KRISTJANPOLLER R.
PROFESOR CORREFERENTE : SR. RODOLFO SALAZAR A.

MARZO 2017

Agradecimientos

Es muy cierto cuando dicen que el camino al éxito es difícil, duro y solitario. Lo he comprobado en muchas etapas de mi vida, y siempre recordaré a aquellas personas que estuvieron junto a mi en los momentos más difíciles, con su aliento y apoyo incondicional. Es a quienes llamo mi familia, no importando si existe vínculo sanguíneo alguno.

Es a aquellas hermosas personas que quiero agradecer, personajes especiales en mi vida, que son nada más y nada menos que un solo conjunto de seres queridos que son benefactores de importancia inimaginable en las circunstancias de mi vida. No podría sentirme más ameno con la confianza puesta sobre mi, especialmente contando con su incondicional amor desde que siquiera tengo memoria.

Este nuevo logro es gran parte gracias a ustedes; he logrado concluir con éxito un proyecto que en un principio podría parecer una tarea titánica e interminable. Quisiera agradecer a ustedes, personas de bien, seres que ofrecen amor, bienestar y finos deleites de vida.

Muchas gracias a aquellos seres queridos que siempre guardo en mi alma.

Dedicatoria.

Deseo dedicar esta tesis a mi hija y mi familia, por ser la llama incandescente de motivación, además de ser el pilar fundamental en todo lo que soy, en toda mi educación, tanto académica, como de vida, por su incondicional apoyo perfectamente mantenido a través del tiempo. Todo este trabajo ha sido posible gracias a ellos.

RESUMEN EJECUTIVO

El siguiente estudio pretende identificar la mejor metodología para realizar las proyecciones de cálculo del Value at Risk (VaR) o Valor en Riego, para el caso de dos monedas y ocho commodities; los modelos utilizados se pueden clasificar en modelos no paramétricos (HS: Simulación Histórica), semiparamétricos (CAViaR: Conditional Autoregressive Value at Risk y paramétricos (EGARCH: Exponential, Generalized, Autoregressive, Conditional Heteroscedasticity). La data completa se desagregó en dos períodos uno de Pre Crisis (antes del 2008) y otro de Post Crisis (posterior a 2008). Los resultados de los modelos que no fueron rechazados y que representan una eficiente proyección de VaR para cada commodity y moneda, en sus respectivos períodos de datos, se presenta a continuación:

Tabla 1: Modelos válidos para commodities analizados en todos los períodos

Commodities	Data Total	Pre Crisis	Post Crisis
EUR	Caviar	HS / Garch / Caviar	Garch / Caviar
LIB	Caviar	HS / Garch / Caviar	Caviar
SIL		HS / Caviar	
GOL	Caviar	HS / Garch	HS / Garch / Caviar
COP	Caviar	HS / Garch / Caviar	Caviar
BRE	Caviar	HS / Caviar	Garch / Caviar
WTI	Caviar	HS / Caviar	Garch / Caviar
GAS	Caviar	Caviar	Caviar
CSA	Caviar	HS / Caviar	Garch / Caviar
CEU	Caviar	Garch / Caviar	HS / Garch / Caviar

Para todos los periodos, incluyendo *crisis subprime*, y analizando los modelos y los resultados obtenidos por las proyecciones con las diferentes metodologías y los *backtest* se puede concluir que el CAViaR es el método más eficiente en la protección del VaR para todos los commodities y monedas.

ABSTRACT

En esta Tesis de Grado se analizaron tres metodologías para el cálculo del Value at Risk (VaR) o Valor en Riesgo; modelos no paramétricos, semiparamétricos y paramétricos. El objetivo es evaluar la validez de cada uno de estos modelos para los períodos en análisis: Data Total (julio 2006 - abril 2016), Data Periodo Pre Crisis Subprime (julio 2006 - diciembre 2007), Data Periodo Post Crisis Subprime (enero 2009 - abril 2016). Se eligió un modelo representativo para cada metodología: Simulación Histórica (HS) para los modelos no paramétricos, CAVIAR para los semiparamétricos y EGARCH para los paramétricos. Para validar cada modelo en cada período se utilizó el método propuesto por Candelon *et al.* (2011), un *backtest* basado en el método general de los momentos. Las variables a pronosticar fueron los tipos de cambio Euro / Dólar y Libra / Dólar, además de los principales commodities tranzados a nivel mundial, Plata (SIL), Oro (GOL), Cobre (COP), Petroleo Brent (BRE), Petroleo WTI (WTI), Gas Natural (GAS), Carbón de Sudáfrica (CSA) y Carbón de Europa (CEU). Los resultados muestran que el modelo semiparamétrico, CAViaR, es el más adecuado para proyectar el VaR para las monedas y commodities en los períodos analizados.

Índice de Contenidos

1. Introducción y Problema de Investigación	1
1.1. Introducción	1
1.2. Problema de Investigación	4
1.3. Objetivo General	6
1.4. Objetivos Específicos	6
2. Marco Teórico	7
2.1. Conceptos Básicos	9
2.2. Value At Risk: Descripción Conceptual	10
2.3. Value At Risk: Evolución Teórica	11
2.3.1. Leavens (1945) ¹	11
2.3.2. Markowitz y Roy (1952)	12
2.3.3. Tobin (1958)	12
2.3.4. Treynor (1961)	13
2.3.5. Sharpe (1964), Lintner(1965) y Mossin (1966)	13
2.3.6. Schrock (1971) y Dusak (1972)	14
2.3.7. Lietaer (1971)	14
2.3.8. Garbade (1986-1987)	15
2.3.9. Jorion (1997)	15
2.3.10. Till Guldemann (1980)	16
2.3.11. Acerbi y Tasche (2002)	16
2.3.12. Embrechts, McNeil y Straumann (2002)	16
2.3.13. Engle (1982)	17
2.3.14. Bollerslev (1986)	18
2.3.15. Engle y Manganelli (1999)	18
2.3.16. Danielson y Vries (2000)	19
2.4. Value At Risk: Modelos GARCH	21
2.4.1. Modelo EGARCH	22
2.4.2. Modelo TGARCH	23
2.4.3. Modelo PGARCH	24
2.5. Value At Risk: Algunas Aplicaciones al mercado de Acciones	24
2.5.1. Angelidis, Benos y Degiannakis (2004)	24
2.5.2. So y Yu (2006)	25

¹Glyn A. Holton (2002). *History of Value-at-Risk: 1922-1998*.

2.5.3.	Allen y Singh(2010)	25
2.5.4.	Jeon y Taylor(2012)	26
2.6.	Value At Risk: Algunas Aplicaciones al Mercado de Commodities	27
2.6.1.	Chaker Aloui (2008)	31
2.6.2.	Hung, Lee y Liu (2008)	31
2.6.3.	Wan-Hsiu y Jui-Cheng (2011)	32
2.6.4.	Hammoudeh, Santos y Al-Hassan (2013)	32
2.6.5.	Rondinone (2015)	33
2.6.6.	Ewa Ratuszny (2015)	33
3.	Data y Metodología	34
3.1.	Data	35
3.1.1.	Tipo de Cambio EUR / USD: EUR	35
3.1.2.	Libra: LIB	36
3.1.3.	Plata: SIL	38
3.1.4.	Oro: GOL	39
3.1.5.	Cobre: COP	40
3.1.6.	Petróleo Brent: BRE	42
3.1.7.	Petróleo WTI: WTI	43
3.1.8.	Gas Natural: GAS	44
3.1.9.	Carbón Sudáfrica: CSA	46
3.1.10.	Carbón Europa: CEU	47
3.1.11.	Resumen Data Total	48
3.1.12.	Resumen Data Pre Crisis	50
3.1.13.	Resumen Data Post Crisis	52
3.2.	Metodología	55
3.2.1.	HS: Historical Simulation.	55
3.2.2.	CAViaR: Conditional Autoregressive Value at Risk.	56
3.2.3.	EGARCH: Exponential, Generalized, Autoregressive, Conditional Heteroscedasticity.	57
3.3.	Backtesting	57
4.	Análisis de Resultados	64
4.1.	Período Data Total (Julio 2006 - Abril 2016)	64
4.2.	Período Pre Crisis (Julio 2006 - Diciembre 2007)	67
4.3.	Período Post Crisis (Enero 2009 - Abril 2016)	70
5.	Conclusiones	74
6.	Referencias Bibliográficas	79
A.	Anexos	83
A.1.	Test Augmented Dickey Fuller	83
A.2.	Test Levene	88
A.3.	Resultados Data Total	94
A.3.1.	EUR	94

A.3.2. LIB	97
A.3.3. SIL	100
A.3.4. GOL	103
A.3.5. COP	106
A.3.6. BRE	109
A.3.7. WTI	112
A.3.8. GAS	115
A.3.9. CSA	118
A.3.10. CEU	121
A.4. Resultados Gráficos Data Total	124
A.4.1. EUR	124
A.4.2. LIB	125
A.4.3. SIL	126
A.4.4. GOL	127
A.4.5. COP	128
A.4.6. BRE	129
A.4.7. WTI	130
A.4.8. GAS	131
A.4.9. CSA	132
A.4.10. CEU	133

Índice de Tablas

1. Modelos válidos para commodities analizados en todos los períodos . . .	III
3.1. Estadística Descriptiva EUR	35
3.2. Test ADF para serie de retornos EUR	36
3.3. Test Levene para la serie EUR	36
3.4. Estadística Descriptiva LIB	36
3.5. Test ADF para serie de retornos LIB	37
3.6. Test Levene para la serie LIB	37
3.7. Estadística Descriptiva SIL	38
3.8. Test ADF para serie de retornos SIL	38
3.9. Test Levene para la serie SIL	39
3.10. Estadística Descriptiva GOL	39
3.11. Test ADF para serie de retornos GOL	39
3.12. Test Levene para la serie GOL	40
3.13. Estadística Descriptiva COP	40
3.14. Test ADF para serie de retornos COP	41
3.15. Test Levene para la serie COP	41
3.16. Estadística Descriptiva BRE	42
3.17. Test ADF para serie de retornos BRE	42
3.18. Test Levene para la serie BRE	43
3.19. Estadística Descriptiva WTI	43
3.20. Test ADF para serie de retornos WTI	43
3.21. Test Levene para la serie WTI	44
3.22. Estadística Descriptiva GAS	44
3.23. Test ADF para serie de retornos GAS	45
3.24. Test Levene para la serie GAS	45
3.25. Estadística Descriptiva CSA	46
3.26. Test ADF para serie de retornos CSA	46
3.27. Test Levene para la serie CSA	47
3.28. Estadística Descriptiva CEU	47
3.29. Test ADF para serie de retornos CEU	47
3.30. Test Levene para la serie CEU	48
3.31. Estadística Descriptiva Resumen Data Total	49
3.32. Test ADF resumido para todas las series Data Total	49
3.33. Resumen test de Levene Data Total	50
3.34. Estadística Descriptiva Resumen Pre Crisis	51

3.35. Test ADF resumido para todas las series Data Pre Crisis	51
3.36. Resumen test de Levene Pre Crisis	52
3.37. Estadística Descriptiva Resumen Post Crisis	53
3.38. Test ADF resumido para todas las series Data Post Crisis	54
3.39. Resumen test de Levene Post Crisis	55
4.1. Modelos válidos para commodities analizados en total data.	65
4.2. Mínimos p -valor para cada una de las pruebas realizadas, total data. . . .	65
4.2. Continuación...	66
4.3. Modelos válidos para commodities analizados en Pre Crisis.	68
4.4. Mínimos p -valor para cada una de las pruebas realizadas, Pre Crisis. . . .	68
4.4. Continuación...	69
4.5. Modelos válidos para commodities analizados en Post Crisis.	71
4.6. Mínimos p -valor para cada una de las pruebas realizadas, Post Crisis. . .	71
4.6. Continuación...	72
5.1. Modelos válidos para commodities analizados en todos los periodos . . .	75
5.2. Resumen mínimos p -valor para cada una de las pruebas realizadas. . . .	77

Índice de Figuras

2.1. Representación Gráfica de Value At Risk	10
2.2. Distribución de retornos SP-500 (1990-1996) ajustada a cola superior . .	20
2.3. Distribución de retornos SP-500 y Mayores Predicciones de GARCH . . .	21
A.1. Test ADF para serie EUR	83
A.2. Test ADF para serie LIB	84
A.3. Test ADF para serie SIL	84
A.4. Test ADF para serie GOL	85
A.5. Test ADF para serie COP	85
A.6. Test ADF para serie BRE	86
A.7. Test ADF para serie WTI	86
A.8. Test ADF para serie GAS	87
A.9. Test ADF para serie CSA	87
A.10. Test ADF para serie CEU	88
A.11. Test Levene para serie EUR	88
A.12. Test Levene para serie LIB	89
A.13. Test Levene para serie SIL	89
A.14. Test Levene para serie GOL	90
A.15. Test Levene para serie COP	90
A.16. Test Levene para serie BRE	91
A.17. Test Levene para serie WTI	91
A.18. Test Levene para serie GAS	92
A.19. Test Levene para serie CSA	92
A.20. Test Levene para serie CEU	93
A.21. Resultado HS para EUR	124
A.22. Resultado GARCH para EUR	124
A.23. Resultado CAVIAR para EUR	124
A.24. Resultado HS para LIB	125
A.25. Resultado GARCH para LIB	125
A.26. Resultado CAVIAR para LIB	125
A.27. Resultado HS para SIL	126
A.28. Resultado GARCH para SIL	126
A.29. Resultado CAVIAR para SIL	126
A.30. Resultado HS para GOL	127
A.31. Resultado GARCH para GOL	127

A.32.Resultado CAVIAR para GOL	127
A.33.Resultado HS para COP	128
A.34.Resultado GARCH para COP	128
A.35.Resultado CAVIAR para COP	128
A.36.Resultado HS para BRE	129
A.37.Resultado GARCH para BRE	129
A.38.Resultado CAVIAR para BRE	129
A.39.Resultado HS para WTI	130
A.40.Resultado GARCH para WTI	130
A.41.Resultado CAVIAR para WTI	130
A.42.Resultado HS para GAS	131
A.43.Resultado GARCH para GAS	131
A.44.Resultado CAVIAR para GAS	131
A.45.Resultado HS para CSA	132
A.46.Resultado GARCH para CSA	132
A.47.Resultado CAVIAR para CSA	132
A.48.Resultado HS para CEU	133
A.49.Resultado GARCH para CEU	133
A.50.Resultado CAVIAR para CEU	133

1 | Introducción y Problema de Investigación

1.1. Introducción

Al estudiar los orígenes del mercado y formas de hacer negocios encontraremos la más simple de las estructuras, *el trueque*, donde las personas se especializaban en algún producto que posteriormente cambiaban por otro que satisficiera sus necesidades, es así como no existía ningún tipo de riesgo en estas transacciones. Sin embargo, este sistema resultó ser poco eficiente a medida que avanzaban o se hacían mas específicas las necesidades. Por tal motivo, se necesitó de un medio que facilitara los intercambios haciéndolos más dinámicos y globales, dando lugar al papel moneda, llegando a ser fundamental en el comercio entre personas, empresas y países. Este instrumento impulsó la globalización de los mercados donde cualquier persona puede participar; es así como nace el riesgo (riesgo de tipo de cambio, cartera, operacional, financiero, etc.), determinado por la incertidumbre ante posibles cambios futuros impredecibles, o en simples palabras nace el miedo a perder riqueza en post de mayores beneficios impulsados por la codicia. Miedo al cual todos los agentes han estado expuestos desde los primeros comerciantes en los antiguos imperios coloniales hasta la transacción de acciones tecnológicas en las distintas bolsas de comercio de todo el mundo. Dado lo anterior, los participantes del mercado se ven obligados a establecer un equilibrio entre el riesgo de sus inversiones y su potencial rentabilidad. Es así que, por un largo tiempo, el riesgo solo se ha cuantificado mediante la desviación estándar o varianza, que caracteriza la volatilidad de la rentabilidad de un activo, sin embargo, esta medida es deficiente al proyectar los riesgos en el futuro con cierto nivel de certidumbre. Es acá donde nace el *Value at Risk* (VaR), que se define como la cuantificación máxima, para un determinado nivel de confianza, del monto o porcentaje de pérdida que un activo o

portfolio enfrentará, en un período predefinido de tiempo (Jorion, 1997). Su medición tiene fundamentos estadísticos y el estándar de la industria es calcular el VaR con un nivel de significancia del 5 %. Esto significa que solamente el 5 % de las veces, o 1 de 20 veces (es decir una vez al mes con datos diarios, o una vez cada 5 meses con datos semanales) el retorno del activo o portafolio caerá más de lo que señala el VaR.

El Value at Risk ha sido impulsado mundialmente por el Comité de Basilea, el cual tiene una larga trayectoria en la gestión del riesgo y en el robustecimiento del Sistema Financiero Mundial. Si bien es cierto que las normas y acuerdos publicados por el Comité son obligatorios solamente para los países pertenecientes al G10 ², muchos otros países colaboran con éste en sus objetivos y algunos de ellos han adoptado varias de las normas y acuerdos fijados por el Comité a través de sus organismos supervisores, como es el caso de Chile. No es sino hasta el acuerdo de Basilea II, en el año 2004, que permitió a todas las instituciones formular sus propias metodologías, donde nacen técnicas académicamente aceptadas como la Simulación Histórica (HS, *Historical Simulation*), Valor en Riesgo Condicional Autoregresivo (CAViaR, *Conditional Autoregressive Value at Risk*) y los modelos Generalizados de Heterocedasticidad Condicional Autoregresiva (GARCH, *Generalized Autoregressive Conditional Heteroscedasticity*). Por lo tanto, en una diversidad de modelos y técnicas académicas, resulta de gran relevancia conocer qué modelo es el mejor para cada activo, en este caso commodities y monedas. Por lo tanto, a fin de conocer que metodología es la más apropiada para calcular el Valor en Riesgo para cada activo individual, se realizará un *backtest* compuesto por tres diferentes pruebas: de Cobertura Condicional (CC, *Conditional Coverage*), Cobertura Incondicional (UC, *Unconditional Coverage*) y de Independencia (IND, *Independence*), de acuerdo a la metodología de Candelon *et al.* (2011).

A continuación, se revisará la problemática de estudio, los objetivos generales y específicos, además de la evolución histórica del Valor en Riesgo, completando el marco teórico. Una vez establecidas las bases académicas, se analizará la data y metodologías utilizadas para el análisis del mercado de commodities y monedas, para continuar con el análisis de

²Países miembros del Comité de Basilea: Bélgica, Canadá, Francia, Alemania, Italia, Japón, Luxemburgo, Holanda, España, Suecia, Suiza, el Reino Unido y Estados Unidos.

resultados obtenidos, finalizando con las conclusiones.

1.2. Problema de Investigación

El VaR se ha popularizado ya hace casi una década, siendo cada vez más utilizado en los mercados financieros desarrollados a través de todo el mundo, principalmente por bancos, debido a la globalización de los mercados que requiere de una actualización de las metodologías de evaluación de riesgo, considerando el nacimiento de activos financieros difíciles de evaluar y commodities que se tranzan a nivel mundial, por su carácter de materias primas necesarias para la operación de grandes industrias.

La importancia de esta metodología radica en la administración eficiente de activos, donde es fundamental poder estimar el riesgo asociado a una cierta composición de cartera o materias primas, si consideramos que al analizar un proyecto de inversión, su atractivo depende no tan sólo de su rentabilidad sino también de su riesgo.

En específico, los mercados de materias primas o commodities son mercados mundiales, los que se caracterizan por tranzar productos de bajo nivel de diferenciación, estandarizados y no manufacturados. Los más importantes son la Bolsa de Metales de Londres (LME), Chicago Board of Trade (CBOT) y New York Mercantile Exchange (NYMEX), donde se tranzan en presente, futuro y opciones. En este contexto y dado que los precios de las materias primas es una variable exógena para las industrias, donde estos commodities representan el costo más importante dentro de su estructura, es necesario tomar decisiones con la menor incertidumbre posible, lo que significa que las empresas e instituciones financieras deben contar con la mayor cantidad de información disponible, no solo en cuanto a rentabilidad sino también a la exposición al riesgo, dado que la principal forma de transacción es a futuro, y por consiguiente, los precios pueden variar en el mediano y largo plazo, dejando posiciones sin cubrir o riesgos que no se han visualizado.

Acá es donde el concepto de *Value at Risk* (valor en riesgo, el cual proviene de la necesidad de cuantificar con determinado nivel de significancia o incertidumbre, el monto o porcentaje de pérdida que un activo enfrentará en período predefinido de tiempo) toma real importancia, dado que las empresas e instituciones financieras deben conocer con exactitud la exposición al riesgo en cuanto a las decisiones o contratos que firman de mediano y largo plazo. Por ejemplo, para las empresas del rubro termoeléctrico (en base a carbón),

donde el principal costo de operación es el carbón, un *commodity* que principalmente se transa a futuro con contratos de largo plazo y donde el precio es fijado por las bolsas internacionales, aún cuando el despacho e ingreso a producción puede incluso demorar un año. Si esta industria no conoce como modelar de mejor manera la cantidad que esta dispuesta a perder en un periodo predefinido de tiempo, significa que no conoce los riesgos a los que está expuesto, y no tienen poder de gestión sobre la proyección de sus resultados.

Por lo tanto, resulta importante conocer cual es el modelo válido para calcular el VaR, ya sea EGARCH (Exponential Generalized Autoregressive Conditional Heteroscedasticity), CAViaR (valor en riesgo condicional autoregresivo) o Simulación Histórica (HS), mediante un *backtest* compuesto por tres diferentes pruebas: de Cobertura Condicional (CC, *Conditional Coverage*), Cobertura Incondicional (UC, *Unconditional Coverage*) y de Independencia (IND, *Independence*), de acuerdo a la metodología de Candelon *et al.* (2011).

1.3. Objetivo General

El Objetivo General de este estudio es analizar la validez de los modelos paramétricos, semiparamétricos y no paramétricos, para determinar cual es el mejor para cada activo (commodities) en el período de tiempo considerado. Para cada modelo se eligió un método representativo, EGARCH (Exponential Generalized Autoregressive Conditional Heteroscedasticity) para los paramétricos, CAViaR (valor en riesgo condicional autoregresivo) para los semiparamétricos y Simulación Histórica (HS) para los NO paramétricos.

1.4. Objetivos Específicos

- **Comprender la evolución histórica del Valor en Riesgo.** Es preciso lograr un conocimiento profundo de cómo y por qué han evolucionado las distintas técnicas del valor en riesgo, con el objetivo de ser preciso en el análisis de la data y metodología a implementar.
- **Comprender las variables involucradas en la determinación del VaR y sus interrelaciones.** Conociendo la definición básica del valor en riesgo se logra una mayor comprensión de las variables involucradas en las distintas metodologías derivadas del modelo original.
- **Intuir las exposiciones en el mercado de commodities en la industria nacional.** Al calcular el valor en riesgo para el mercado de commodities indirectamente se pueden establecer las exposiciones que tienen las compañías en el mercado nacional.
- **Establecer las diferencias y aplicaciones de los distintos modelos.** Es necesario conocer en qué casos o para qué indicadores los modelos paramétricos, no paramétricos y semiparamétricos son útiles o cual es el más adecuado dependiendo del tipo de dato o industria donde se aplicará el valor en riesgo.

2 | Marco Teórico

La medición de los riesgos financieros ha contribuido a tomar mejores decisiones en beneficio de la administración de riesgos dentro del mundo empresarial o la economía de un país. El riesgo financiero proviene de tres fuentes:

- El riesgo de mercado, definido como la incertidumbre causada por los cambios en los factores que afectan al mercado, como las tasas de interés, tasas de cambio, precio de las acciones y los precios de las materias primas, entre otras.
- El riesgo de crédito, el cual proviene de las pérdidas asociadas con el incumplimiento o rebaja de crédito de un deudor.
- El riesgo operacional, relacionado con fallas operacionales de las empresas o entidades.

El Comité de Supervisión Bancaria publica el acuerdo de Basilea I, donde se considera el denominado Valor al Riesgo (VaR) como una medida para la exposición al riesgo del mercado que tienen los bancos. En términos de pérdidas, el VaR a un nivel de confianza α , es la frontera inferior de las 100 $(1 - \alpha) \%$ mayores pérdidas durante un horizonte de tiempo. Para determinar dicha frontera, el acuerdo de Basilea establece $\alpha = 0.99$ y un tiempo de 10 días. Existen tres tipos de modelos para estimar el VaR:

- **Paramétricos:** que suponen una distribución para los datos financieros que por experiencia se sabe que presentan sesgo y colas pesadas.
- **No Paramétricos:** que utilizan los cuantiles empíricos, por lo que son adecuados para modelar datos con colas pesadas.

- **Semiparamétricos:** que suponen una distribución para una cola pero no suponen distribución alguna para lo que está fuera de ella.

En teoría existen muchas explicaciones del por qué los datos financieros tienen colas pesadas, siendo dos de las más aceptadas: (1) la existencia de cambios significativos discontinuos llamados “saltos” causados por cambios inesperados en los factores de mercado, y (2) la alta correlación que presenta la volatilidad con volatilidades pasadas. La volatilidad representa la variación de los precios de los activos que en muchas ocasiones es estimada a través de la desviación estándar de los precios o de los rendimientos. La modelación de la volatilidad de las series financieras es un campo de creciente investigación en Finanzas y Economía. En finanzas es frecuente hablar de generación de expectativas a partir de situaciones que sucedieron en el pasado. Por ejemplo, se relaciona la estabilidad o inestabilidad presente en los mercados financieros con su comportamiento inmediato anterior. Además, un cambio brusco en el mercado está seguido de una evolución tranquila. En situaciones como estas, el comportamiento en el momento actual responde a una expectativa generada sobre el valor de cambio producido en el momento precedente; es decir, a un valor esperado condicionado por la varianza del período anterior. Engle (1982) propone un modelo que expresa una varianza condicional como función lineal del cuadrado de los valores pasados del modelo; este modelo es conocido como el modelo Autorregresivo Condicional Heterocedástico (ARCH), por lo tanto para comprender los modelos que se aplicarán, a continuación se revisarán los aspectos más básicos del VaR y su evolución histórica.

2.1. Conceptos Básicos

Rendimiento Esperado³: Es el rendimiento que un inversionista espera que gane una acción en el siguiente período. Debido a que esto es una expectativa, el rendimiento real puede ser más alto o más bajo. La expectativa se puede basar solo en el rendimiento promedio por periodo que un instrumento haya ganado en el pasado, como también se puede basar en un análisis de los proyectos de la empresa, información interna, etc.

Varianza y Desviación Estándar: Son una medida de las desviaciones del rendimiento de un instrumento respecto de su rendimiento esperado. Medida que nos sirve para evaluar la volatilidad de una acción.

Covarianza: Miden la forma como se relacionan dos variables aleatorias, es una medida de dispersión conjunta de dos variables.

Correlación: Indica la fuerza y dirección de una relación lineal entre dos variables.

Cobertura: En finanzas, (en inglés *hedging* o *hedge*) se llama al conjunto de operaciones dirigidas a anular o reducir el riesgo de un activo o pasivo financiero que posee una empresa o un particular. Los fondos creados con este fin se denominan fondos de cobertura o *hedge funds*.

Skewness: Medida de asimetría que permiten establecer el grado de simetría (o asimetría) que presenta una distribución de probabilidad de una variable aleatoria.

Kurtosis: En teoría de probabilidad y estadística, la Kurtosis es una medida que sirve para analizar el grado de concentración que presentan los valores de una variable analizada alrededor de la zona central de la distribución de frecuencias.

³Capítulo 10, *Finanzas Corporativas*. Ross, Westerfield, Jaffe.

2.2. Value At Risk: Descripción Conceptual

El concepto de Value at Risk (VaR), o valoración del riesgo, proviene de la necesidad de cuantificar con determinado nivel de significancia o incertidumbre el monto o porcentaje de pérdida que un portafolio enfrentará en un período predefinido de tiempo (Jorion 2000, Penza y Bansal 2001, Best 1998, y Dowd 1998).⁴

Si consideramos una serie de retornos históricos de un portafolio que posee un número n de activos, es factible visualizar la distribución de densidad de aquellos retornos a través del análisis del histograma. Una vez generada la distribución se debe calcular aquel punto del dominio de la función de densidad que deja un 5 % o 1 % del área en su rango inferior (α). La distancia de este punto en el dominio de la distribución en relación al valor esperado de la distribución se denomina Value at Risk.




Figura 2.1: Representación Gráfica de Value At Risk

Analíticamente, el VaR se define por el límite superior de la integral de la función de retornos esperados:

$$\int_{-\infty}^{E[r]-VaR} r(s)ds = \alpha \quad (2.1)$$

⁴Christian A. Johnson (2001). Value At Risk: Teoría y Aplicaciones. *Estudios de Economía*, Vol 28. Banco Central de Chile

Aunque una representación alternativa consiste en estimar el VaR a través de la siguiente expresión:

$$VaR = \alpha \cdot \sqrt{\sigma^2 \cdot \Delta t} \quad (2.2)$$

Donde α es el factor que define el área de pérdida de los retornos, σ^2 la varianza de los retornos, y Δt el horizonte de tiempo para el cual se calculará el factor de riesgo VaR.

2.3. Value At Risk: Evolución Teórica

El Valor en Riesgo (VaR) no es un concepto que emane de *la nada*, pues surge de la aplicación de los principios de la *Teoría de Portfolios* a la gestión y valorización del riesgo de una posición de mercado. Según estas teorías, una cartera será eficiente cuando maximice su rendimiento para un determinado nivel de riesgo o, de otro modo, cuando minimice su riesgo para un nivel dado de rentabilidad. Por eso es necesario sentar las bases de la evolución histórica del VaR.

2.3.1. Leavens (1945)⁵

Los orígenes de la teoría de portfolio se pueden remontar a las discusiones no matemáticas de construcción de carteras. Autores como Hardy (1923) y Hicks (1935) comentan intuitivamente la importancia de la diversificación. Posteriormente, Leavens (1945) presentó un ejemplo cuantitativo, que puede ser la primera medida de VaR que haya sido publicada.

Leavens consideró un portfolio de diez bonos durante un horizonte. Cada bono maduraría al final del horizonte por USD 1.000 o se declararía en default, sin valor (estos eventos de default son asumidos como independientes). Así entonces, el valor de la cartera tenía una distribución binomial.

Escribiendo para un público no técnico, Leavens no identificó explícitamente el VaR, pero mencionó varias veces el "*spread* entre las probables pérdidas y ganancias". Pareciera que había tenido la desviación estándar del valor de mercado del portfolio en mente.

⁵Glyn A. Holton (2002). *History of Value-at-Risk: 1922-1998*.

Esta fue la primera aproximación a la desviación estándar de un portfolio y como la diversificación ofrecía ventajas para manejarla.

2.3.2. Markowitz y Roy (1952)

Markowitz (1952) y, tres meses más tarde, Roy (1952), publicaron de forma independiente, cálculos de VaR que eran sorprendentemente similares. Cada uno estaba trabajando para desarrollar un método de selección de carteras que, en cierto sentido, optimizara la rentabilidad para un nivel dado de riesgo. Con este fin, cada uno propone medidas de VaR que incorporaron covarianzas entre factores de riesgo con el objetivo de reflejar los efectos de cobertura y diversificación. Mientras que las dos medidas eran matemáticamente similares, proponían diferentes cálculos del VaR. Markowitz utilizó una variación sencilla de la rentabilidad, mientras que Roy utilizó un indicador de riesgo que representaba un límite superior a la probabilidad de retorno bruto de la cartera. Tanto Markowitz y Roy abordaron la cuestión de cómo podrían ser especificadas las hipótesis probabilísticas y sentaron las bases sobre la diversificación de portfolios.

2.3.3. Tobin (1958)

Tobin desarrolló un trabajo teórico apuntando a la definición de VaR, para dos posiciones, demanda de dinero o rentabilidad por tasa de interés, es decir, analizando la preferencia por liquidez y su impacto en el valor de la cartera, ante los aumentos de tasas.

Una de las relaciones funcionales básicas en el modelo keynesiano de la economía es el esquema de preferencia por la liquidez, una relación inversa entre la demanda de saldos de efectivo y la tasa de interés. Esta función debe derivarse de algunas suposiciones sobre el comportamiento de toma de decisiones de la economía. Lo que hay que explicar no es sólo la existencia de una demanda de dinero en efectivo cuando su rendimiento es menor que el rendimiento sobre los activos alternativos, sino una relación inversa entre la demanda agregada de dinero en efectivo y el tamaño de este diferencial de rendimientos. (Tobin, 1958).

2.3.4. Treynor (1961)

Treynor aborda la teoría del valor de mercado que incorpora el riesgo, teniendo en cuenta un modelo altamente idealizado de un mercado de capitales en el que es relativamente fácil ver cómo las primas de riesgo implícitas en los precios de las acciones están relacionadas con las decisiones de cartera de los inversores individuales. Los inversores pueden ser diversos, dependiendo de su capital, aversión hacia el riesgo y en la combinación de las inversiones que asumen, pero si sus proyecciones (probabilísticas) del valor futuro son iguales, entonces la composición proporcional de los activos de riesgo deben ser la misma. A menos que el inversionista prefiera el efectivo, recibirá un retorno de su capital en la tasa de interés libre de riesgo, el valor esperado depende sólo de la prima de riesgo de las respectivas inversiones y la proporción que el inversor elige para mantener en cada uno. Se desarrolla el concepto prima de riesgo que resulta útil para hablar sobre el problema de portfolio, junto con la incertidumbre asociada a una determinada inversión.

2.3.5. Sharpe (1964), Lintner(1965) y Mossin (1966)

Sobre el trabajo de Harry Markowitz (1952) se desarrollaron estudios sobre la medición del concepto del VaR, sin definirlo con claridad. Sin embargo, introdujeron un modelo de valoración de activos financieros (CAPM), el cual es un modelo para calcular el precio de un activo y pasivo o una cartera de inversiones. Para activos individuales, se hace uso de la recta *stock market line* (*SML*) la cual simboliza el retorno esperado de todos los activos de un mercado como función del riesgo no diversificable y su relación con el retorno esperado y el riesgo sistémico (β), para mostrar cómo el mercado debe estimar el precio de un activo individual en relación a la clase a la que pertenece. La relación de equilibrio que describe el CAPM es:

$$E(r_i) = r_f + \beta_m \cdot (E(r_m) - r_f) \quad (2.3)$$

Donde:

$E(r_i)$: es la tasa de rendimiento esperada de capital sobre el activo i .

β_m : es el beta o cantidad de riesgo con respecto al portafolio de mercado.

$(E(r_m) - r_f)$: es el exceso de rentabilidad del portafolio sobre el mercado.

r_m : rendimiento de mercado.

r_f : rendimiento de un activo libre de riesgo.

2.3.6. Schrock (1971) y Dusak (1972)

Describen simples mediciones de lo que se conoce como VaR para portfolio de futuros, pero sin abordar los términos de estructura o estacionalidad de los datos. Dusak analizó la larga controversia sobre si los especuladores en un mercado de futuros ganan una prima de riesgo en el contexto del modelo de valoración de activos de capital anteriormente desarrollado por Sharpe , Lintner , y otros. Bajo este planteamiento, la prima de riesgo requerida en un contrato de futuros no debe depender de la variabilidad de los precios, sino en la medida en que las variaciones de los precios están sistemáticamente relacionados con las variaciones en el rendimiento de la riqueza total . El riesgo sistemático se estimó para una muestra de los contratos de futuros de trigo , maíz y soja, durante el período 1952-1967 y se encontró cerca de cero en los tres casos . Por otro lado, los rendimientos medios obtenidos en los contratos durante el mismo período fueron cercanas a cero. Relación riesgo versus retorno.

2.3.7. Lietaer (1971)

Este autor describe una medida práctica del VaR para el riesgo por tipo de cambio. Además escribió en el último período de tipos de cambio fijos, que el riesgo se manifestaba, así mismo, como una devaluación en las monedas. Desde la Segunda Guerra Mundial , la mayoría de las monedas se habían devaluado en algún momento, algunas lo habían hecho varias veces. Los gobiernos eran reservados sobre las devaluaciones programadas, por lo que las corporaciones mantenían continuas coberturas. Lietaer (1971) propuso un sofisticado procedimiento para la optimización de dichas coberturas, incorporando una medida de VaR con una varianza de valor de mercado. Se supone que las devaluaciones ocurrieron al azar, con la magnitud condicional de una devaluación que se distribuye normalmente. Los cálculos se simplificaron utilizando una modificación del modelo de Sharpe (1963). El trabajo de Lietaer puede ser la primera vez que el método de Monte

Carlo se empleó en el cálculo del VaR.

2.3.8. Garbade (1986-1987)

Durante la década de 1980, Kenneth Garbade trabajó en *Bankers Trust Cross Markets Research Group* desarrollando técnicas sofisticadas de modelamiento para el mercado de bonos de Estados Unidos. Como parte de los esfuerzos de marketing de la empresa, preparó varios informes de investigación para distribuir a los clientes institucionales. Dos de estos, Garbade (1986, 1987), describieron sofisticadas medidas de VaR para la evaluación de requerimiento capital.

El VaR de Garbade (1986) modeló cada bono en base a su sensibilidad de los precios ante cambios en el rendimiento o tasa, suponiendo que los valores de mercado de la cartera se distribuían de forma normal. Dada una matriz de covarianzas de rendimientos a distintos vencimientos, se determinó la desviación estándar del valor de la cartera. Con esta caracterización se calculó el VaR, utilizando el análisis de componentes principales para reducir la dimensionalidad del problema. Garbade (1987) extendió su trabajo introduciendo un esquema que le permitió reasignar una amplia cartera de bonos a una más pequeña que sólo tuviese los bonos más representativos, logrando desagregar el riesgo de un portfolio.

2.3.9. Jorion (1997)

Es el primero en formalizar el valor en riesgo y lo define como la cuantificación con determinado nivel de significancia o incertidumbre del monto o porcentaje de máxima pérdida que un portfolio enfrentará en un periodo predefinido de tiempo.

En palabras de Jorion (1997):

"El valor en riesgo mide la pérdida máxima esperada, o peor pérdida, en un intervalo de tiempo determinado, bajo condiciones normales del mercado, y para nivel de confianza dado".

2.3.10. Till Guldumann (1980)

Durante la década de 1980 *JP Morgan* desarrolló un sistema basado en el VaR a través de toda la compañía, este modelaba varios cientos de factores de riesgo. Una matriz de covarianzas que se actualizaba trimestralmente a partir de datos históricos, estos fueron agregados o consolidados para expresar el valor de la cartera como un polinomio lineal de los factores de riesgo, de estos se calculó la desviación estándar de la cartera. Se emplearon varios modelos y uno de ellos fue en un día el VaR al 95 %, el cual se calculó suponiendo una distribución normal. El arquitecto de esta medida y creador formal de VaR fue Till Guldumann, quien en su carrera en *JP Morgan*, contribuyó a desarrollar y promover el VaR dentro y fuera de la compañía.

2.3.11. Acerbi y Tasche (2002)

Han demostrado que tomando una expectativa condicional de pérdidas más allá del VaR, puede fallar en producir una medida de riesgo coherente cuando hay discontinuidades en las distribuciones de pérdidas. Esto significa que el VaR no satisface las propiedades de subaditividad de las medidas de riesgo coherentes para análisis de diversificación de diferentes activos que componen una cartera de inversión.

2.3.12. Embrechts, McNeil y Straumann (2002)

Demuestran que el VaR si cumple la propiedad de subaditividad de las medidas de riesgo, cuando la rentabilidad de los activos cumplen con tener una distribución normal o *t-student*. Sin embargo, la mayoría de las distribuciones de rentabilidad de los activos no cumplen esta propiedad, pueden ser transformadas por medio de una expresión de Cornish-Fisher (Favre y Galeano, 2002), que mediante la curtosis y asimetría crea un Z que se asemeja mucho a la Z normal.⁶

⁶Werner Kristjanpoller y Andrés Barahona (2014). *Backtesting del valor en riesgo para los mercados bursátiles y de divisas latinoamericanas*.

2.3.13. Engle (1982)

Engle plantea los modelos de Heterocedasticidad Condicional Autoregresiva (ARCH, *Autoregressive Conditional Heteroscedasticity*) originando una familia de modelos que calculan la varianza condicional de mediciones pasadas, siendo ésta no constante (heterocedástica), calculando la variabilidad de una proyección. Para estos procesos, el pasado reciente proporciona información acerca de la varianza del pronóstico de un período.

Sea (ε_t) una sucesión de variables aleatorias independientes e idénticamente distribuidas (i.i.d.) con distribución normal estándar $N(0,1)$. Entonces (y_t) es un proceso ARCH(q) si:

$$y_t = \sigma_t \varepsilon_t$$

donde

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i y_{t-i}^2 \quad (2.4)$$

con $\omega > 0$, $\alpha_i \geq 0$, $i=1, \dots, q$.

La ecuación (2.4) implica que la varianza condicional σ_t^2 evoluciona según los valores previos de y_{t-i}^2 , es decir:

$$y_t^2 = \omega + \sum_{i=1}^q \alpha_i y_{t-i}^2 + \eta_t \quad (2.5)$$

para alguna variable aleatoria η_t .

Una característica de este modelo es que la distribución condicional de y_t dada la información obtenida hasta el tiempo $t-1$ se distribuye $N(0, \sigma_t^2)$. Esto se obtiene del hecho de que ε_t y σ_t^2 son independientes, ya que por la ecuación (2.4), σ_t^2 depende de los errores anteriores a t , es decir, de $\varepsilon_{t-1}, \dots, \varepsilon_{t-q}$.

Una motivación adicional para definir los modelos ARCH es que si y_t es el logaritmo del precio de una acción al tiempo t y esta serie es diferenciada una vez, se observa que tiene un comportamiento correspondiente al denominado ruido blanco, y usualmente un modelo ARIMA(0,1,0) es adecuado para modelar la serie (y_t) . Sin embargo, la serie diferenciada está altamente autocorrelacionada, y éstas autocorrelaciones son casi siempre no negativas, lo cual contradice la definición de ruido blanco (Chan, 2002).

Aún cuando el modelo ARCH permite modelar varianzas, dependientes del tiempo y varias propiedades de las series de rendimientos financieros, tiene el inconveniente de que el valor de q en el modelo de series de tiempo financieras tiende a ser grande. Además, el supuesto de no negatividad de los parámetros puede no cumplirse cuando el número de éstos se incrementa.

2.3.14. Bollerslev (1986)

Bollerslev introduce el modelo GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*), mejora la especificación original del modelo ARCH añadiendo varianza condicional rezagada, la cual actúa como un término suavizador, por lo que evita las dificultades mencionadas al permitir que las volatilidades pasadas impacten en la volatilidad actual.

Sea (ε_t) una sucesión de variables aleatorias independientes e idénticamente distribuidas (i.i.d.) con distribución normal estándar $N(0,1)$. Entonces el proceso (y_t) es un proceso GARCH(p,q) si:

$$y_t = \sigma_t \varepsilon_t$$

donde

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i y_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (2.6)$$

con $\omega > 0$, $\alpha_i \geq 0$, $i=1, \dots, q$ y $\beta_j \geq 0$, $j=1, \dots, p$.

Como se observa, en los procesos GARCH(p,q), la varianza condicional no sólo depende de los cuadrados de las perturbaciones, sino además de las varianzas condicionales de períodos anteriores. Si en el proceso GARCH(p,q) se tiene $\beta_j = 0$, $j = 1, \dots, p$, entonces el proceso resultante es un ARCH(q).

2.3.15. Engle y Manganelli (1999)

Proponen un enfoque diferente a la estimación de cuantiles. En lugar de modelar toda la distribución, modelan el cuantil directamente. El hecho empírico de que las volatilidades

de los rendimientos del mercado de valores se agrupan en el tiempo se puede traducir en términos estadísticos diciendo que su distribución es autocorrelacionada. En consecuencia, el valor en riesgo, que está estrechamente ligado a la desviación estándar de la distribución, debe presentar un comportamiento similar. Una forma natural de formalizar esta característica es usar algún tipo de especificación autorregresiva. Se propone una especificación en cuantil autorregresivo condicional, lo que denominan CAViaR.

Se supone que se observa un vector de retornos del portafolio $\{y_t\}_{t=1}^T$. Sea θ la probabilidad asociada con el VaR. Sea x_t un vector de variables observables en tiempo t , y β_θ un vector p de parámetros desconocidos. Finalmente, $f_t(\beta) \equiv f_t(x_{t-1}, \beta_\theta)$ denota el cuantil θ al tiempo t de la distribución de rendimientos de la cartera formados en tiempo $t - 1$, en el que se suprime el subíndice θ de β_θ por conveniencia en notación. Una especificación genérica del CAViaR podría ser la siguiente:

$$f_t(\beta) = \beta_0 + \sum_{i=1}^q \beta_i f_{t-i}(\beta) + \sum_{j=1}^r \beta_j l(x_{t-j}) \quad (2.7)$$

donde $p = q + r + 1$ es la dimensión de β y l es una función finita de valores de rezagos observables. El término autoregresivo $\beta_i f_{t-i}(\beta)$, $i=1, \dots, q$, asegura que los cambios en los cuantiles sean suaves a través del tiempo. Por otro lado, el rol de $l(x_{t-j})$ es relacionar $f_t(\beta)$ con las variables observables que pertenecen al conjunto de información disponible. Así este término tiene el mismo rol que la curva de nuevos impactos para los modelos GARCH.

2.3.16. Danielson y Vries (2000)

Danielson y Vries proponen y definen los modelos semiparamétricos, donde se encuentran los modelos de teoría de valor extremo (EVT, *Extreme Value Theory*).

La predicción exacta de las realizaciones extremas es de importancia central para el análisis VaR. Las estimaciones de VaR se calculan desde el extremo inferior de una distribución de pronóstico de la cartera. Por lo tanto, la estimación precisa de la cola inferior de la rentabilidad de la cartera es trascendente en cualquier aplicación de VaR. La mayoría de las herramientas disponibles, tales como GARCH, están diseñados para predecir volatilidades comunes, y por lo tanto tienen malas propiedades de cola. Incluso Simulación

Histórica (HS) tienen menos propiedades deseables de muestreo en las colas. Por lo tanto, una técnica híbrida que combina el muestreo de la distribución empírica para observaciones comunes con el muestreo de una distribución de cola ajustada, tiene potencial para modelar mejor que el método de Simulación Histórica o cualquier método paramétrico.

En la Figura 2.2, se presenta la distribución empírica del índice SP-500 junto con la distribución de cola ajustada $F(x)$ y la distribución normal estimada. Se puede ver el problema con las colas de la HS, por ejemplo, diferencias en las observaciones y la incapacidad para proporcionar bajas predicciones de probabilidad fuera de la muestra. La distribución Normal claramente subestima la probabilidad de los rendimientos más altos. Por otro lado, la distribución ajustada es una función suave a través de la distribución empírica, tanto dentro como fuera de la muestra. A modo de comparación, en la figura 2.3 se grafica la distribución ajustada junto con la distribución normal estimada de la media y varianza muestral y la distribución obtenida desde un proceso GARCH (1,1) en condiciones con máxima volatilidad pasada observada. Esto grafica la distribución normal, con la varianza de las mayores predicciones de volatilidad del GARCH en un día. Desde que la distribución condicional es aún normal ésta subestima los extremos de las colas.

Distribution of SP-500 Returns 1990-1996 with Fitted Upper Tail





Figura 2.2: Distribución de retornos SP-500 (1990-1996) ajustada a cola superior

Distribution of SP-500 Returns 1990-1996 and Highest GARCH Prediction**Figura 2.3:** Distribución de retornos SP-500 y Mayores Predicciones de GARCH

Varios métodos han sido propuestos para la estimación del VaR, algunos están basados en las volatilidades condicionales como el GARCH, basado en el método de RiskMetrics, otras creen en la incondicionalidad de la distribución de los retornos, como la Simulación Histórica. Danielson y Vries propusieron el uso del Método de Valor Extremo (EVT) como un método semiparamétrico para la estimación de probabilidades de cola. Demostraron que los métodos paramétricos condicionales como los GARCH, subestiman el VaR para una muestra de acciones de Estados Unidos, con un 1 % de nivel de riesgo. Por otro lado, el método de Simulación Histórica se desempeña mejor en la predicción del VaR, pero sufre de una alta varianza y muestreo discreto lejos de las colas. Por otra parte, la Simulación Histórica es incapaz de hacer frente a las pérdidas fuera de la muestra. Finalmente demostraron que el desempeño del estimador del método de Valor Extremo funciona mejor en las colas que el método GARCH de RiskMetrics y el método de Simulación Histórica.

2.4. Value At Risk: Modelos GARCH

Al analizar una serie de tiempo puede observarse que las denominadas malas noticias tienen un efecto más fuerte en la volatilidad que las buenas noticias. Más aún, se ha detectado que para algunos mercados de valores existe una correlación negativa entre el rendimiento actual y la volatilidad futura (Suliman y Winker, 2012). A la tendencia

que tiene la volatilidad de decrecer cuando los rendimientos se incrementan se conoce comúnmente como efecto de apalancamiento (Enders, 2004). En esta situación, los modelos GARCH poseen la desventaja de que la varianza condicional no es capaz de modelar los cambios asimétricos de los incrementos y decrementos de los rendimientos y_t . En el modelo GARCH(p, q) la varianza condicional es función de dos elementos: las varianzas condicionales pasadas y los cuadrados de las innovaciones. Esto hace que el signo de los rendimientos no afecte la volatilidad, como lo señalan Knight y Satchell (2007), lo que tiene como consecuencia que un modelo GARCH tradicional no tenga la capacidad de modelar el efecto de apalancamiento antes descrito.

En la literatura se han propuesto algunas maneras para modelar ese efecto por medio de los denominados modelos asimétricos. Los más conocidos en la práctica son el EGARCH (Nelson, 1991), el TGARCH (Zakoian, 1994) y el PGARCH (Ding *et al.*, 1993), los cuales se presentan a continuación.

2.4.1. Modelo EGARCH

El modelo GARCH exponencial (EGARCH, por sus siglas en inglés) fue propuesto por Nelson (1991). Tiene la virtud de modelar el comportamiento asimétrico de la varianza que depende del tiempo y a su vez garantizar que la varianza sea siempre positiva. Por ejemplo, el proceso (y_t) siguiendo un modelo EGARCH(1,1) tiene la forma:

$$y_t = \sigma_t \varepsilon_t$$

donde ε_t se supone con una distribución normal y

$$\log(\sigma_t^2) = \omega + \beta_1 \log(\sigma_{t-1}^2) + \alpha_1 \left\{ \left| \frac{y_{t-1}}{\sigma_{t-1}} \right| - \sqrt{\frac{2}{\pi}} \right\} - \gamma \frac{y_{t-1}}{\sigma_{t-1}} \quad (2.8)$$

En la ecuación anterior el parámetro γ modela la asimetría, es decir, el apalancamiento. En la práctica, se espera que el signo del parámetro γ sea positivo, por lo que un impacto negativo incrementará la volatilidad futura (incertidumbre), mientras que un impacto positivo facilita el efecto en incertidumbres futuras. Por el contrario, para el modelo GARCH, los efectos de la misma magnitud, ya sea positiva o negativa, tienen el mismo efecto en la volatilidad futura.

En general, el proceso y_t sigue un modelo EGARCH(p, q) si:

$$y_t = \sigma_t \varepsilon_t$$

donde ε_t se supone con una distribución normal y

$$\log(\sigma_t^2) = \omega + \sum_{j=1}^p \beta_j \log(\sigma_{t-j}^2) + \sum_{i=1}^q \left[\alpha_i \left\{ \left| \frac{y_{t-i}}{\sigma_{t-i}} \right| - \sqrt{\frac{2}{\pi}} \right\} - \gamma \frac{y_{t-i}}{\sigma_{t-i}} \right] \quad (2.9)$$

2.4.2. Modelo TGARCH

Otro proceso para modelar efectos asimétricos, que fue propuesto por Zakoian (1994), se conoce como modelo GARCH por umbrales (TGARCH, por sus siglas en inglés). En su versión más sencilla, es decir, TGARCH(1,1), la varianza condicional se modela como:

$$\sigma_t^2 = \omega + \alpha_1 \varepsilon_{t-1}^2 + \gamma_1 d_{t-1} \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

donde d_{t-1} es una variable *dummy* dada por:

$$d_{t-1} = \begin{cases} 1 & \text{si } \varepsilon_{t-1} < 0 \text{ (malas noticias)} \\ 0 & \text{si } \varepsilon_{t-1} \geq 0 \text{ (buenas noticias)} \end{cases}$$

La variable d_i usa un umbral igual a cero para clasificar los impactos pasados. En la práctica se pueden usar otros valores para el umbral, como propone Tsay (2010). El coeficiente γ_1 corresponde al parámetro de apalancamiento y cuando $\gamma_1 = 0$, el modelo corresponde a un GARCH(1,1) estándar. De acuerdo con este modelo, cuando se tiene un impacto positivo (buenas noticias) el efecto que se tiene en la volatilidad es igual a α_1 . Asimismo, cuando el impacto es negativo (malas noticias) el efecto en la volatilidad es $\alpha_1 + \gamma_1$. El parámetro β_1 cumple las mismas condiciones que en el modelo GARCH. Dado lo anterior, si γ_1 es positivo y con un valor significativo, los impactos negativos tendrán un mayor efecto en σ_t^2 que impactos positivos.

El modelo TGARCH(p, q), que es la postulación general, tiene la siguiente expresión para la varianza condicional:

$$\sigma_t^2 = \omega + \sum_{i=1}^q (\alpha_i + \gamma_i d_{t-i}) \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (2.10)$$

donde α_i , γ_i y β_j son parámetros no negativos que satisfacen condiciones similares a las de los modelos GARCH y d_{t-i} se define de manera análoga que en la ecuación anterior.

2.4.3. Modelo PGARCH

Otro modelo que incorpora la asimetría de la distribución de los rendimientos es el conocido como Modelo GARCH potencia (PGARCH, por sus siglas en inglés), propuesto por Ding *et al.* (1993). A diferencia de modelar la varianza, como lo hacen los modelos GARCH tradicionales, se modela una potencia de la desviación estándar. Para considerar la asimetría, en los modelos PGARCH pueden considerarse parámetros adicionales (en el caso de PGARCH(1,1) será γ), de manera opcional. De acuerdo con el modelo PGARCH general, se tiene que:

$$\sigma_t^\delta = \omega + \sum_{j=1}^p \beta_j \sigma_{t-j}^\delta + \sum_{i=1}^q \alpha_i (|\varepsilon_{t-i}| - \gamma_i \varepsilon_{t-i})^\delta \quad (2.11)$$

donde los parámetros α_i y β_j poseen las mismas características que los modelos ARCH y GARCH estándares, γ_i son los parámetros de apalancamiento y δ es el parámetro para el término de potencia. Si se postula el valor $\delta = 2$, el modelo PGARCH es equivalente al modelo GARCH clásico con efecto de apalancamiento. Por su parte, cuando $\delta = 1$ entonces se estima la desviación estándar condicional. En el modelo PGARCH es posible considerar un modelo aún más flexible si se considera δ como otro parámetro a estimar (Zivot, 2008; Ocran y Biekets, 2007).

2.5. Value At Risk: Algunas Aplicaciones al mercado de Acciones

2.5.1. Angelidis, Benos y Degiannakis (2004)

Aplicaron los modelos GARCH, EGARCH y TGARCH a los indicadores S&P500, Nikkei225, DAX30, CAC40 y FTSE100. Evaluaron el desempeño de una extensa familia de modelos ARCH modelando el VaR diariamente de un portfolio perfectamente diversificado

para cinco índices accionarios, usando una serie de supuestos de distribución y tamaño de muestras. Encontraron, primero, que las distribuciones leptocúrticas son capaces de producir mejores pronósticos de VaR, segundo, que la elección del tamaño de la muestra es importante para la exactitud de la proyección, mientras que la especificación de la media condicional es indiferente. Finalmente la estructura ARCH que produce los pronósticos o proyecciones más precisas es diferente para cada portfolio y cada índice accionario.

2.5.2. So y Yu (2006)

Analizaron empíricamente los modelos ARCH en el VaR mediante modelos GARCH, IGARCH (GARCH integrado), FIGARCH (GARCH fraccionado) y RiskMetrics para diversos indicadores y tipos de cambios asiáticos. Estudiaron siete modelos GARCH, incluyendo RiskMetrics y dos modelos GARCH de memoria larga, en la estimación del Valor en Riesgo (VaR). Se consideraron ambas posiciones largas y cortas de la inversión. Los siete modelos se aplicaron a 12 índices de mercado y cuatro tipos de cambio para evaluar cada modelo en la estimación del valor en riesgo en los distintos niveles de confianza. Los resultados indican que ambos modelos GARCH, estacionarios y fraccionalmente integrados, superan a RiskMetrics en la estimación de VaR al 1 %. Aunque la mayoría de la serie muestran distribución de cola gruesa y satisfacen la propiedad de memoria de larga, es más importante tener en cuenta un modelo con un error de cola gruesa en la estimación del VaR. También se descubre que el comportamiento asimétrico en los datos del mercado de valores, donde los modelos basados en estadístico *t* – *Student* dan mejores estimaciones de VaR al 1 % que los modelos basados en el error *normal* en una posición larga, pero no en posiciones cortas. Sin embargo, esta asimetría no es observada en los datos de tipo de cambio.

2.5.3. Allen y Singh(2010)

Aplicaron el CAViaR para obtener el riesgo del mercado de acciones australianas y además contrastaron los resultados con los obtenidos desde un modelo GARCH (1,1), método RiskMetrics y el modelo APARCH (Asymmetric Power ARCH Model). Allen y

Singh(2010) plantean que los resultados del VaR al 1 % y al 5 % para el conjunto de datos de Australia comparten muchas características comunes con los presentados por Engle y Manganelli (2004) por su conjunto de datos de Estados Unidos que contó con General Motors, IBM y el índice S&P 500. Un resultado notable es que el término autorregresivo es siempre muy importante. Esto coincide con los resultados e implica que la agrupación volatilidad también es importante en las colas de las distribuciones, en estos casos , en cuantiles extremos. Todos los modelos parecen ser de alta precisión, tal como se mide por el éxito en la muestra. Para el VaR al 1 % todos los valores están muy cerca de 1 , siendo el más débil el modelo adaptativo. El panorama es similar para el valor en riesgo al 5 % el caso más débil es de nuevo el modelo adaptativo.

2.5.4. Jeon y Taylor(2012)

Aplicaron CAViaR y otros modelos para proyectar el riesgo en el S&P500 y DAX30. Propusieron métodos de estimación del Valor en Riesgo (VaR) que son una síntesis de valor condicional autorregresivo en riesgo (CAViaR) modelos de series temporales y volatilidad implícita. El atractivo de esta propuesta es que se combina la información de las series de tiempo históricas y las diferentes informaciones suministradas por las expectativas de riesgo del mercado. También investigaron incluir la volatilidad implícita en el modelo CAViaR, un procedimiento que no había sido considerado hasta el momento. Los resultados para el índice de rentabilidad diaria indican que los nuevos métodos propuestos son comparables o superiores a los métodos individuales, tales como los modelos estándar de CAViaR y los construidos en cuantiles a partir de la volatilidad implícita y la distribución empírica de los residuos estandarizados. Encontraron que la volatilidad implícita tiene más poder explicativo como el foco se mueve más lejos en la cola izquierda de la distribución condicional de S&P 500 para retornos diarios.

2.6. Value At Risk: Algunas Aplicaciones al Mercado de Commodities

La literatura de los commodities se está ampliando y ganando importancia como resultado del crecimiento significativo del rol que estos activos desempeñan en los mercados financieros internacionales y en las economías globales. Actualmente existen más productos negociados en bolsa (ETCs, exchange traded commodities) y los fondos negociados en bolsa (ETFs, exchange traded funds) se están creando para productos específicos, siendo fuerte en ciertos productos o como híbridos de materias primas y acciones tales como el índice CRB (Global Commodity Equity Index Fund)⁷. Barclays crea un ETF basado en el índice basado en el índice Goldman Sachs Commodity Index (GSCI), siguiendo 24 commodities a través de los sectores de la energía, metal, agricultura y ganadería. Los más recientes y prometedores ETF se han creado para el platino y palladium. A continuación, se presenta una revisión de los estudios existentes enfatizando la importancia económica en relación con la escasa literatura sobre metales preciosos y materias primas energéticas.

Jensen , Johnson , y Mercer (2002) encuentran que los futuros de materias primas mejoran sustancialmente el rendimiento del portafolio para los inversores, muestran que los beneficios de la adición de futuros de materias primas se acumulan casi exclusivamente cuando la Reserva Federal está siguiendo una política monetaria restrictiva. En general, los hallazgos indican que los inversores deben evaluar las condiciones monetarias para determinar la asignación óptima de los futuros de materias primas dentro de una cartera. Draper *et al.* (2006) examinan el papel de inversión de metales preciosos en los mercados financieros usando datos diarios para oro, plata y platino. Ellos muestran que los tres metales preciosos tienen una baja correlación con los rendimientos de acciones estadounidenses, lo que sugiere que estos metales proporcionan la diversificación dentro de las carteras de inversión. También muestran que los tres metales preciosos tienen capacidad de cobertura para desempeñar el papel de fondos seguros, en particular durante los períodos de volatilidad anormales.

⁷Deutsche Bank introduce la primera lista de ETFs de commodities en febrero 2006

Hammoudeh y Yuan (2008), aplican modelos GARCH univariantes para investigar las propiedades de volatilidad de dos metales preciosos, oro y plata, y un metal base, el cobre. Usando el modelo GARCH univariante estándar, encuentran que el oro y la plata tenían casi la misma persistencia en la volatilidad, mientras que la persistencia fue mayor para el cobre, procíclica. Canover, Jensen, Johnsos, y Mercer (2009) presentan nueva evidencia sobre los beneficios de la adición de metales preciosos (oro, plata y platino) a carteras de acciones de Estados Unidos. Ellos encuentran que la adición de un 25 % de metales en las acciones de las firmas de metales preciosos mejora el rendimiento de la cartera sustancialmente, y que el oro relacionado con el platino y la plata tiene un rendimiento mejor, por si solo, y parece proporcionar una mejor protección contra los efectos negativos de las presiones inflacionarias. También muestran que, si bien los beneficios de la adición de metales preciosos para una cartera de inversión variaron un poco con el tiempo, prevalecieron durante gran parte del período, 34 años.

Los precios de los metales preciosos, el petróleo y las acciones han sido muy volátiles en el pasado, y aún más recientemente. El entorno de precio volátil del metal precioso requiere la cuantificación del riesgo de mercado. Entonces el VaR se han convertido en una herramienta esencial dentro de los mercados financieros para cuantificar y evaluar el riesgo de mercado de la cartera, es decir, el riesgo asociado a los movimientos de precios (Christoffersen, 2009; Jorion, 2007 para una descripción detallada de VaR). Un modelo de VaR determina la pérdida máxima esperada que una cartera pueda generar durante un cierto periodo de tiempo, con un valor de probabilidad pre-determinado. Por lo tanto, el VaR se puede utilizar, por ejemplo, para evaluar el desempeño de los gestores de cartera, proporcionando la cuantificación del riesgo, junto con los rendimientos de la cartera. Por otra parte, el VaR pueden ayudar a los gerentes de portfolio a determinar la estrategia de gestión de riesgos más adecuada para una situación dada.

Por lo tanto, el VaR se han convertido en una medida estándar de riesgo de mercado y es ampliamente utilizado por los intermediarios financieros y los bancos (véase Comité de Supervisión Bancaria de Basilea, 1988, 1995, 1996; Pérignon y Smith, 2010), los mercados de valores (Bali, Moc, y Tanga 2008; McAleer y da Veiga, 2008a, 2008b; McAleer, Jiménez-Martín, y Pérez-Amaral, 2009; McAleer, Jiménez-Martín, y Pérez-

Amaral, 2010), los mercados de energía (Cabedo y Moya, 2003; Marimoutou, Raggd, y Trabelsi, 2009), entre otros. Como se mencionó anteriormente, a pesar de la importancia de los metales preciosos y su naturaleza volátil, existen pocos estudios que estiman VaR para los metales preciosos. Hammoudeh et al. (2013) utilizan modelos VaR para analizar el riesgo de mercado inconveniente asociado a las inversiones unilaterales en oro, plata, platino y paladio. Los modelos de estimación incluyen RiskMetrics, GARCH (1,1), FHS basados en GARCH, GARCH con distribución t – *Student* y GARCH-FHS (*Filtered Historical Simulation*). Sus resultados sugieren que los gestores de carteras en metales preciosos que deseen seguir una estrategia conservadora deberán calcular el VaR utilizando GARCH- t ya que esto dará lugar a un menor número de violaciones, aunque con una menor rentabilidad. Como se ha indicado antes, Hammoudeh *et al.* (2011) no utiliza los últimos avances en técnicas de estimación y no construye carteras óptimas y fronteras eficientes basadas en VaR.

El método de VaR también se ha utilizado para medir y evaluar el riesgo de mercado en la industria de la energía. Hung, Lee, y Liu (2008) utilizan tres modelos GARCH (GARCH-N, GARCH-T y GARCH-HT) para estimar y comparar la precisión y la eficiencia de los modelos de valor para los precios diarios, al contado, de cinco productos de energía, el petróleo crudo WTI, el petróleo crudo Brent, petróleo de calefacción N°2, el propano y la gasolina convencional del puerto de Nueva York. Los resultados sugieren que las estimaciones de VaR generados por los modelos GARCH-HT tienen una buena precisión en los niveles bajos y altos de confianza. Además, también implican que los modelos de VaR son adecuados para las materias primas energéticas. Marimoutou *et al.* (2009) aplican modelos EVT incondicionales y condicionales para pronosticar el valor en riesgo en el mercado del petróleo. Los resultados de estos modelos se comparan con las de los modelos convencionales, tales como GARCH, HS y FHS. La EVT condicional y FHS ofrecen una mejora importante sobre los otros métodos en estudio. Sin embargo, GARCH (1,1) modelo t puede proporcionar resultados igualmente buenos que son comparables a las de los métodos condicionales y FHS. Estos autores subrayan la importancia del filtrado en el pronóstico de VaR. Aloui y Mabrouk (2010) calculan el VaR por tres modelos tipo ARCH/GARCH incluyendo FIGARCH, FIAPARCH y HYGARCH. Ellos muestran que

con la consideración de la memoria de largo alcance, colas gruesas y modelos asimétricos, desempeñan mejor en la predicción de un valor en riesgo de un día a la vez para ambas posiciones comerciales cortas y largas. Además, el modelo FIAPARCH supera a los otros modelos en la predicción del VaR. Cabedo y Moya (2003) examinan tres métodos de estimación del VaR : el enfoque estándar de simulación histórica , la simulación histórica con los pronósticos ARMA enfoque (HSAF) y el método de la varianza-covarianza basado en pronósticos de los modelos ARCH para cuantificar el riesgo del precio del petróleo. Los resultados muestran que la metodología HSAF proporciona una cuantificación de VaR flexible, que se ajusta a los movimientos continuos del precio del petróleo y así proporciona la cuantificación del riesgo eficiente.

El análisis de riesgo extremo mediante el modelo general de distribución de Pareto (GPD) cobró impulso en las últimas dos décadas como resultado de las altas oscilaciones y choques violentos en los precios de acciones y commodities. McNeil (1997, 1998) investiga riesgos extremos en series de tiempo financieras, utilizando la teoría del valor extremo. Embrechts (1999, 2000) demuestra la solidez de EVT en las estimaciones de riesgo. McNeil y Frey (2000) extienden el análisis de riesgo extremo mediante la combinación de un filtro GARCH con la teoría del valor extremo. Muller, Dacorogna, y Pictet (1998) investigan riesgo extremo en los mercados de divisas utilizando modelos GARCH. Gencay y Selcuk (2004) investigan el rendimiento relativo de los modelos de valor en el uso de EVT, en una serie de mercados emergentes después de la crisis financiera asiática de 1997. Giot y Laurent (2003) modelo de VaR utilizando una serie de modelos univariantes y multivariantes paramétricas de clase ARCH con densidad sesgada $t - Student$.

Bajo la teoría de cartera moderna, los pesos de los activos en una cartera se obtienen mediante la maximización de la prima de riesgo esperado por unidad de riesgo, donde la desviación estándar es la medida de riesgo. Con la presencia de las distribuciones asimétricas y de cola pesadas para los retornos, la desviación estándar como medida de riesgo puede dar lugar a estrategias ineficientes para optimizar las carteras. En la literatura reciente, un nuevo enfoque surgió de maximizar la rentabilidad esperada sujeta a la restricción de riesgo en lugar de la desviación estándar. La construcción de carteras mediante la maximización de rendimiento esperado sujeto a una restricción de déficit tiene

su origen en Roy (1952). Leibowitz y Kogelman (1991) y Lucas y Klaassen (1998) definen la restricción de déficit como un rendimiento mínimo que debe ser adquirido a lo largo de un horizonte de tiempo para un nivel de confianza dado. Campbell, Huisman, y Koedijk (2001) se extienden a la literatura sobre la asignación de activos sujetos a restricciones de déficit, lo que sugiere un modelo de construcción de la cartera basado en el valor en riesgo.

A continuación se detallan algunos importantes estudios recientes:

2.6.1. Chaker Aloui (2008)

Exploró la memoria a largo plazo en la volatilidad en los mercados de energía y el valor en riesgo (VaR). La pregunta principal que se hizo fue ¿se puede estimar mejor el valor en riesgo si existe una memoria de largo plazo?. Para investigar esta cuestión se han aplicado varios procesos, de tipo GARCH incluyendo el proceso FIGARCH a los precios diarios de algunos productos de energía. El valor en riesgo fue estimado para posiciones comerciales, tanto a corto como a largo plazo y en diferentes niveles de confianza. El desempeño del VaR (tipo GARCH) se evaluó mediante la estimación de la tasa de fracaso del estadístico de prueba Kupiec (1995). De acuerdo con estudios anteriores, los resultados muestran que la volatilidad de los precios de la energía exhiben una memoria de largo alcance. El valor en riesgo calculado mediante un proceso FIGARCH $t - Student$ sesgada ofrece el mejor rendimiento para las posiciones de corto y largo plazo.

2.6.2. Hung, Lee y Liu (2008)

La elección de una adecuada distribución de los retorno es importante en aplicaciones del VaR, debido a su capacidad de afectar directamente a la calidad de la estimación de los cuantiles requeridos. Estos autores investigaron la influencia del proceso de innovaciones de cola gruesa sobre el desempeño de las estimaciones del VaR con un día de antelación, utilizando tres modelos GARCH (GARCH-N, GARCH-T y GARCH-HT). Los precios spot diarios de cinco productos energéticos (petróleo crudo WTI, Brent de petróleo crudo, combustible para calefacción #2, propano y gasolina regular convencional del puerto de Nueva York) se utilizan para comparar la precisión y la eficiencia de los modelos VaR.

Los resultados empíricos sugieren que para los rendimientos de los activos que exhiben características leptocúrticas y de cola gruesa, las estimaciones de VaR generados por los modelos GARCH-HT tienen una buena precisión para ambos niveles de confianza, bajos y altos. Además, MRSB (The Mean Relative Scaled Bias) indica que el modelo GARCH-HT es más eficiente que las alternativas, para la mayoría de los casos, en los niveles de confianza elevados. Estos hallazgos sugieren que la distribución de cola pesada es más adecuada para los productos energéticos, en particular para el cálculo del VaR.

2.6.3. Wan-Hsiu y Jui-Cheng (2011)

Utilizan la distribución generalizada sesgada más flexible t (SGT) para la descripción de las volatilidades del petróleo y del metal que se caracterizan por leptokurtosis y asimetría, con el fin de proporcionar mejores aproximaciones a la realidad. Los resultados empíricos indican que los pronósticos de Valor en Riesgo (VaR) obtenidos utilizando la distribución SGT ofrece los más precisos pronósticos fuera de muestra para los mercados tanto del petróleo y como del metal. Con respecto a las pruebas de cobertura incondicionales y condicionales, la distribución SGT produce las estimaciones de VaR más apropiadas en términos de la cantidad total de rechazos; esto es seguido por la distribución no paramétrica, la distribución de error generalizada (GED), y finalmente la distribución normal. Del mismo modo, en la prueba de cuantil dinámico, las estimaciones de VaR generados por el SGT y las distribuciones no paramétricas se desempeñan mejor que la generada por otras distribuciones.

2.6.4. Hammoudeh, Santos y Al-Hassan (2013)

El Valor en Riesgo (VaR) se utilizó para analizar la volatilidad del mercado asociado a las inversiones en seis activos individuales, incluyendo cuatro metales preciosos, el petróleo y el índice S&P 500, y tres carteras diversificadas. Usando combinaciones de estos activos se construyeron tres portafolios óptimos y sus fronteras eficientes dentro de un marco de VaR y se analizaron también los rendimientos y riesgos para estas carteras. Los pronósticos de VaR de un día de antelación se calculan con nueve modelos de riesgo, incluyendo la

metodología RiskMetrics, modelos de tipo GARCH asimétricos, el enfoque de Simulación Histórica filtrada, metodologías de estadísticas de los extremos y una estrategia de gestión del riesgo que incluye combinaciones de modelos, lo cuales son evaluados y comparados en base a la cobertura incondicional, independencia y criterios de cobertura condicionales. La importancia económica de los resultados también se pone en relieve mediante la evaluación de los requerimientos de capital diarios bajo la regla Acuerdo de Basilea. Se discuten los mejores enfoques para estimar el valor en riesgo de los activos individuales en estudio y para las tres carteras óptimas basadas en VaR y fronteras de eficiencia.

2.6.5. Rondinone (2015)

Rondinone (2015) someten a prueba el nivel de sensibilidad del precio de commodities agrícolas frente a shocks en la tasa de interés mediante un sistema de vectores autorregresivos que evalúan la reacción de los precios ante alteraciones en la tasa de interés.

2.6.6. Ewa Ratuszny (2015)

Comparó los métodos VaR (CAViaR) para commodities. Para la medida de riesgo utiliza: el Valor en Riesgo Condicional Autorregresivo (CAViaR), un modelo de cuantil implícito y un método de *Encompassing*. El objetivo es comprobar si el uso simultáneo de información de series de tiempo histórica y la información relacionada con las expectativas de mercado, puede mejorar la precisión de los pronósticos. Para este fin se utilizan cuatro métodos combinados de pronósticos: una simple combinación de promedios, una combinación lineal sin restricciones, un promedio ponderado combinado y un promedio ponderado que usa una ponderación exponencial. El método de elección del modelo más adecuado conduce a un sencillo modelo CAViaR-SAV como la fuente de medida más óptima de los pronóstico de riesgo.

3 | Data y Metodología

Los valores a analizar son dos de las principales monedas tranzadas a nivel mundial, el tipo de cambio euro / dólar (EUR) y libra / dólar (LIB). Además de ocho de commodities: Plata (SIL: expresado en dólares por onza), Oro (GOL: expresado en dólares por onza), Cobre (COP: expresado en dólares por tonelada métrica), Petróleo Brent (BRE: expresado en dólares por barril), Petróleo WTI (WTI: expresado en dólares por barril), Gas Natural (GAS: expresado en dólares por BTU ⁸), Carbón de origen en Sudáfrica (CSA: expresado en dólares por tonelada métrica) y Carbón de origen en Europa (CEU: expresado en dólares por tonelada métrica).

La información fue obtenida de la base de datos de Bloomberg, a través del departamento de Combustible de la empresa AES Gener S.A. quienes dada la importancia de sus compras a futuros de combustibles como el carbón, deben monitorear diariamente la evolución y tendencias de los precios de estos commodities, que representan el principal costo de operación variable.

A continuación, se presentará en detalle cada serie de precios de commodities, comprendidos desde el 17 de julio del año 2006 hasta el 29 de abril del 2016, lo que forma un total de 2.555 registros de precios. Además de los correspondientes test descriptivos, así como también la explicación metodológica de cada uno de los modelos, para finalizar con un *backtest* para determinar que modelo predice con más exactitud el Valor en Riesgo, VaR.

⁸British Thermal Unit, de símbolo BTU o BTu, es una unidad de energía. Se usa principalmente en los Estados Unidos. Una BTU equivale aproximadamente a 257 calorías o 1.055,056 joule.

3.1. Data

Se seleccionaron ocho commodities y dos tipos de cambio, cada serie original de precios presentó una condición de NO Estacionario, por lo que se trabajará con los retornos de cada indicador, de acuerdo a la siguiente ecuación:

$$ret_{Y_t} = Ln\left(\frac{Y_t}{Y_{t-1}}\right) \quad (3.1)$$

donde los retornos del indicador Y en el período t corresponde al *logaritmo natural* del precio del commodity en el período t , sobre, el precio del commodity en el periodo $t - 1$.

Con el cálculo de los retornos, el total de observaciones es de 2.554 registros para cada commodity.

3.1.1. Tipo de Cambio EUR / USD: EUR

Estadística Descriptiva

Tabla 3.1: Estadística Descriptiva EUR

Estadístico	EUR	Estadístico	EUR
Mean	-3,508796	Skewness	0,102034
Median	7,377116	Kurtosis	5,211027
Maximum	0,037188	Jarque-Bera	524,664
Minimum	-0,027968	Sum	-0,089615
Std. Dev.	0,006400	Sum Sq. Dev.	0,104575
Observations	2.554		

Test de Estacionariedad

Para comprobar si la serie de retornos de la tasa de cambio EUR/USD es estacionaria, se realizó el test de Dickey Fuller Aumentado, utilizando el criterio automático de Schwartz con un máximo de 26 rezagos, considerando intercepto y tendencia.

Se puede apreciar que el estadístico es mayor que los valores críticos al 1 %, 5 % y 10 %, por lo que se rechaza la hipótesis nula de presencia de raíz unitaria y se concluye que

Tabla 3.2: Test ADF para serie de retornos EUR

EUR		t-statistic	p-value
Augmented Dickey Fuller Test Statistic		-50.05225	0.0000
Test Critical Values	1 %	-3.961638	
	5 %	-3.411568	
	10 %	-3.127650	

la serie es estacionaria.

Test de Heterocedasticidad

Se realizó el test de Levene para comprobar la presencia de heterocedasticidad de la serie, el cual realiza un ANOVA utilizando la prueba de Fisher bajo la hipótesis nula de homocedasticidad. A continuación, se presenta el resultado y su $p - value$, para la serie EUR. El detalle del test se puede encontrar en el anexo A.2.

Tabla 3.3: Test Levene para la serie EUR

SERIE	t-Statistic	p-value	Resultado
EUR	4.039605	0.0071	Heterocedástico

3.1.2. Libra: LIB

Estadística Descriptiva

Tabla 3.4: Estadística Descriptiva LIB

Estadístico	LIB	Estadístico	LIB
Mean	-8,4496	Skewness	-0,4206
Median	0,0000	Kurtosis	6,3895
Maximum	0,0304	Jarque-Bera	1.297,923
Minimum	-0,0393	Sum	-0,2158
Std. Dev.	0,0059	Sum Sq. Dev.	0,0887
Observations	2.554		

Test de Estacionariedad

Para comprobar si la serie de retornos de la tasa de cambio LIB/USD es estacionaria, se realizó el test de Dickey Fuller Aumentado, utilizando el criterio automático de Schwartz con un máximo de 26 rezagos, considerando intercepto y tendencia.

Tabla 3.5: Test ADF para serie de retornos LIB

LIB		t-statistic	p-value
Augmented Dickey Fuller Test Statistic		-48,26120	0.0000
Test Critical Values	1 %	-3.961638	
	5 %	-3.411568	
	10 %	-3.127650	

Se puede apreciar que el estadístico es mayor que los valores críticos al 1 %, 5 % y 10 %, por lo que se rechaza la hipótesis nula de presencia de raíz unitaria y se concluye que la serie es estacionaria.

Test de Heterocedasticidad

Se realizó el test de Levene para comprobar la presencia de heterocedasticidad de la serie, el cual realiza un ANOVA utilizando la prueba de Fisher bajo la hipótesis nula de homocedasticidad. A continuación, se presenta el resultado y su $p - value$, para la serie LIB. El detalle del test se puede encontrar en el anexo A.2.

Tabla 3.6: Test Levene para la serie LIB

SERIE	t-Statistic	p-value	Resultado
LIB	2,664042	0,0464	Heterocedástico

3.1.3. Plata: SIL

Estadística Descriptiva

Tabla 3.7: Estadística Descriptiva SIL

Estadístico	SIL	Estadístico	SIL
Mean	0,0002	Skewness	-0,4219
Median	0,0000	Kurtosis	11,9290
Maximum	0,1828	Jarque-Bera	8.560,008
Minimum	-0,1869	Sum	0,4399
Std. Dev.	0,0229	Sum Sq. Dev.	1,3356
Observations	2.554		

Test de Estacionariedad

Para comprobar si la serie de retornos de la Plata (SIL) es estacionaria, se realizó el test de Dickey Fuller Aumentado, utilizando el criterio automático de Schwartz con un máximo de 26 rezagos, considerando intercepto y tendencia.

Tabla 3.8: Test ADF para serie de retornos SIL

SIL		t-statistic	p-value
Augmented Dickey Fuller Test Statistic		-55,54711	0.0000
Test Critical Values	1 %	-3.961638	
	5 %	-3.411568	
	10 %	-3.127650	

Se puede apreciar que el estadístico es mayor que los valores críticos al 1 %, 5 % y 10 %, por lo que se rechaza la hipótesis nula de presencia de raíz unitaria y se concluye que la serie es estacionaria.

Test de Heterocedasticidad

Se realizó el test de Levene para comprobar la presencia de heterocedasticidad de la serie, el cual realiza un ANOVA utilizando la prueba de Fisher bajo la hipótesis nula de

homocedasticidad. A continuación, se presenta el resultado y su p – *value*, para la serie SIL. El detalle del test se puede encontrar en el anexo A.2.

Tabla 3.9: Test Levene para la serie SIL

SERIE	t-Statistic	p-value	Resultado
SIL	18,27267	0,0000	Heterocedástico

3.1.4. Oro: GOL

Estadística Descriptiva

Tabla 3.10: Estadística Descriptiva GOL

Estadístico	GOL	Estadístico	GOL
Mean	0,0003	Skewness	-0,2365
Median	0,0003	Kurtosis	8,5992
Maximum	0,1039	Jarque-Bera	3.360,126
Minimum	-0,0888	Sum	0,7002
Std. Dev.	0,0121	Sum Sq. Dev.	0,3758
Observations	2.554		

Test de Estacionariedad

Para comprobar si la serie de retornos del Oro (GOL) es estacionaria, se realizó el test de Dickey Fuller Aumentado, utilizando el criterio automático de Schwartz con un máximo de 26 rezagos, considerando intercepto y tendencia.

Tabla 3.11: Test ADF para serie de retornos GOL

GOL		t-statistic	p-value
Augmented Dickey Fuller Test Statistic		-50,15923	0.0000
Test Critical Values	1 %	-3.961638	
	5 %	-3.411568	
	10 %	-3.127650	

Se puede apreciar que el estadístico es mayor que los valores críticos al 1 %, 5 % y 10 %, por lo que se rechaza la hipótesis nula de presencia de raíz unitaria y se concluye que la serie es estacionaria.

Test de Heterocedasticidad

Se realizó el test de Levene para comprobar la presencia de heterocedasticidad de la serie, el cual realiza un ANOVA utilizando la prueba de Fisher bajo la hipótesis nula de homocedasticidad. A continuación, se presenta el resultado y su $p - value$, para la serie GOL. El detalle del test se puede encontrar en el anexo A.2.

Tabla 3.12: Test Levene para la serie GOL

SERIE	t-Statistic	p-value	Resultado
GOL	2,930401	0,0197	Heterocedástico

3.1.5. Cobre: COP

Estadística Descriptiva

Tabla 3.13: Estadística Descriptiva COP

Estadístico	COP	Estadístico	COP
Mean	-0,0002	Skewness	-0,1226
Median	0,0000	Kurtosis	6,2178
Maximum	0,1173	Jarque-Bera	1.108,273
Minimum	-0,1032	Sum	-0,4406
Std. Dev.	0,0186	Sum Sq. Dev.	0,8825
Observations	2.554		

Test de Estacionariedad

Para comprobar si la serie de retornos del Cobre (COP) es estacionaria, se realizó el test de Dickey Fuller Aumentado, utilizando el criterio automático de Schwartz con un máximo de 26 rezagos, considerando intercepto y tendencia.

Tabla 3.14: Test ADF para serie de retornos COP

COP		t-statistic	p-value
Augmented Dickey Fuller Test Statistic		-54,45962	0.0000
Test Critical Values	1 %	-3.961638	
	5 %	-3.411568	
	10 %	-3.127650	

Se puede apreciar que el estadístico es mayor que los valores críticos al 1 %, 5 % y 10 %, por lo que se rechaza la hipótesis nula de presencia de raíz unitaria y se concluye que la serie es estacionaria.

Test de Heterocedasticidad

Se realizó el test de Levene para comprobar la presencia de heterocedasticidad de la serie, el cual realiza un ANOVA utilizando la prueba de Fisher bajo la hipótesis nula de homocedasticidad. A continuación, se presenta el resultado y su $p - value$, para la serie COP. El detalle del test se puede encontrar en el anexo A.2.

Tabla 3.15: Test Levene para la serie COP

SERIE	t-Statistic	p-value	Resultado
COP	1,741825	0,1217	Homocedástico

3.1.6. Petróleo Brent: BRE

Estadística Descriptiva

Tabla 3.16: Estadística Descriptiva BRE

Estadístico	BRE	Estadístico	BRE
Mean	-0,0002	Skewness	0,0144
Median	0,0000	Kurtosis	6,6689
Maximum	0,1271	Jarque-Bera	1.432,549
Minimum	-0,1095	Sum	-0,4558
Std. Dev.	0,0218	Sum Sq. Dev.	1,2165
Observations	2.554		

Test de Estacionariedad

Para comprobar si la serie de retornos del Petróleo Brent (BRE) es estacionaria, se realizó el test de Dickey Fuller Aumentado, utilizando el criterio automático de Schwartz con un máximo de 26 rezagos, considerando intercepto y tendencia.

Tabla 3.17: Test ADF para serie de retornos BRE

BRE	t-statistic	p-value
Augmented Dickey Fuller Test Statistic	-54,08923	0.0000
Test Critical Values	1 % -3.961638	
	5 % -3.411568	
	10 % -3.127650	

Se puede apreciar que el estadístico es mayor que los valores críticos al 1 %, 5 % y 10 %, por lo que se rechaza la hipótesis nula de presencia de raíz unitaria y se concluye que la serie es estacionaria.

Test de Heterocedasticidad

Se realizó el test de Levene para comprobar la presencia de heterocedasticidad de la serie, el cual realiza un ANOVA utilizando la prueba de Fisher bajo la hipótesis nula de

homocedasticidad. A continuación, se presenta el resultado y su $p - value$, para la serie BRE. El detalle del test se puede encontrar en el anexo A.2.

Tabla 3.18: Test Levene para la serie BRE

SERIE	t-Statistic	p-value	Resultado
BRE	3,306208	0,0056	Heterocedástico

3.1.7. Petróleo WTI: WTI

Estadística Descriptiva

Tabla 3.19: Estadística Descriptiva WTI

Estadístico	WTI	Estadístico	WTI
Mean	-0,0002	Skewness	0,1762
Median	0,0000	Kurtosis	7,9176
Maximum	0,1641	Jarque-Bera	2.586,699
Minimum	-0,1307	Sum	-0,4935
Std. Dev.	0,0244	Sum Sq. Dev.	1,5195
Observations	2.554		

Test de Estacionariedad

Para comprobar si la serie de retornos del Petróleo WTI (WTI) es estacionaria, se realizó el test de Dickey Fuller Aumentado, utilizando el criterio automático de Schwartz con un máximo de 26 rezagos, considerando intercepto y tendencia.

Tabla 3.20: Test ADF para serie de retornos WTI

WTI	t-statistic	p-value
Augmented Dickey Fuller Test Statistic	-53,14102	0.0000
Test Critical Values	1 % -3.961638	
	5 % -3.411568	
	10 % -3.127650	

Se puede apreciar que el estadístico es mayor que los valores críticos al 1 %, 5 % y 10 %, por lo que se rechaza la hipótesis nula de presencia de raíz unitaria y se concluye que la serie es estacionaria.

Test de Heterocedasticidad

Se realizó el test de Levene para comprobar la presencia de heterocedasticidad de la serie, el cual realiza un ANOVA utilizando la prueba de Fisher bajo la hipótesis nula de homocedasticidad. A continuación, se presenta el resultado y su $p - value$, para la serie WTI. El detalle del test se puede encontrar en el anexo A.2.

Tabla 3.21: Test Levene para la serie WTI

SERIE	t-Statistic	p-value	Resultado
WTI	1,000773	0,3914	Homocedástico

3.1.8. Gas Natural: GAS

Estadística Descriptiva

Tabla 3.22: Estadística Descriptiva GAS

Estadístico	GAS	Estadístico	GAS
Mean	-0,0004	Skewness	0,7635
Median	0,0000	Kurtosis	8,5433
Maximum	0,2677	Jarque-Bera	3.518,073
Minimum	-0,1489	Sum	-1,0106
Std. Dev.	0,0314	Sum Sq. Dev.	2,5156
Observations	2.554		

Test de Estacionariedad

Para comprobar si la serie de retornos del Gas Natural (GAS) es estacionaria, se realizó el test de Dickey Fuller Aumentado, utilizando el criterio automático de Schwartz con un máximo de 26 rezagos, considerando intercepto y tendencia.

Tabla 3.23: Test ADF para serie de retornos GAS

GAS		t-statistic	p-value
Augmented Dickey Fuller Test Statistic		-54,73156	0.0000
Test Critical Values	1 %	-3.961638	
	5 %	-3.411568	
	10 %	-3.127650	

Se puede apreciar que el estadístico es mayor que los valores críticos al 1 %, 5 % y 10 %, por lo que se rechaza la hipótesis nula de presencia de raíz unitaria y se concluye que la serie es estacionaria.

Test de Heterocedasticidad

Se realizó el test de Levene para comprobar la presencia de heterocedasticidad de la serie, el cual realiza un ANOVA utilizando la prueba de Fisher bajo la hipótesis nula de homocedasticidad. A continuación, se presenta el resultado y su $p - value$, para la serie GAS. El detalle del test se puede encontrar en el anexo A.2.

Tabla 3.24: Test Levene para la serie GAS

SERIE	t-Statistic	p-value	Resultado
GAS	0,330372	0,8577	Homocedástico

3.1.9. Carbón Sudáfrica: CSA

Estadística Descriptiva

Tabla 3.25: Estadística Descriptiva CSA

Estadístico	CSA	Estadístico	CSA
Mean	2,1272	Skewness	0,5267
Median	0,0000	Kurtosis	46,9881
Maximum	0,2384	Jarque-Bera	206.029,585
Minimum	-0,2073	Sum	0,0543
Std. Dev.	0,0158	Sum Sq. Dev.	0,6351
Observations	2.554		

Test de Estacionariedad

Para comprobar si la serie de retornos del Carbón de Sudáfrica (CSA) es estacionaria, se realizó el test de Dickey Fuller Aumentado, utilizando el criterio automático de Schwartz con un máximo de 26 rezagos, considerando intercepto y tendencia.

Tabla 3.26: Test ADF para serie de retornos CSA

CSA	t-statistic	p-value
Augmented Dickey Fuller Test Statistic	-50,23821	0.0000
Test Critical Values	1 % -3.961638	
	5 % -3.411568	
	10 % -3.127650	

Se puede apreciar que el estadístico es mayor que los valores críticos al 1 %, 5 % y 10 %, por lo que se rechaza la hipótesis nula de presencia de raíz unitaria y se concluye que la serie es estacionaria.

Test de Heterocedasticidad

Se realizó el test de Levene para comprobar la presencia de heterocedasticidad de la serie, el cual realiza un ANOVA utilizando la prueba de Fisher bajo la hipótesis nula de

homocedasticidad. A continuación, se presenta el resultado y su $p - value$, para la serie CSA. El detalle del test se puede encontrar en el anexo A.2.

Tabla 3.27: Test Levene para la serie CSA

SERIE	t-Statistic	p-value	Resultado
CSA	0,497124	0,7786	Homocedástico

3.1.10. Carbón Europa: CEU

Estadística Descriptiva

Tabla 3.28: Estadística Descriptiva CEU

Estadístico	CEU	Estadístico	CEU
Mean	-0,0001	Skewness	-1,5620
Median	0,0000	Kurtosis	44,4992
Maximum	0,1641	Jarque-Bera	184.307,574
Minimum	-0,2286	Sum	0,3304
Std. Dev.	0,0154	Sum Sq. Dev.	0,6090
Observations	2.554		

Test de Estacionariedad

Para comprobar si la serie de retornos del Carbón de Europa (CEU) es estacionaria, se realizó el test de Dickey Fuller Aumentado, utilizando el criterio automático de Schwartz con un máximo de 26 rezagos, considerando intercepto y tendencia.

Tabla 3.29: Test ADF para serie de retornos CEU

CEU		t-statistic	p-value
Augmented Dickey Fuller Test Statistic		-48,81137	0.0000
Test Critical Values	1 %	-3.961638	
	5 %	-3.411568	
	10 %	-3.127650	

Se puede apreciar que el estadístico es mayor que los valores críticos al 1 %, 5 % y 10 %, por lo que se rechaza la hipótesis nula de presencia de raíz unitaria y se concluye que la serie es estacionaria.

Test de Heterocedasticidad

Se realizó el test de Levene para comprobar la presencia de heterocedasticidad de la serie, el cual realiza un ANOVA utilizando la prueba de Fisher bajo la hipótesis nula de homocedasticidad. A continuación, se presenta el resultado y su $p - value$, para la serie CEU. El detalle del test se puede encontrar en el anexo A.2.

Tabla 3.30: Test Levene para la serie CEU

SERIE	t-Statistic	p-value	Resultado
CEU	6,628918	0,0000	Heterocedástico

3.1.11. Resumen Data Total

Estadística Descriptiva Data Total

A continuación se presenta la estadística descriptiva para todas las series para el periodo Data Total.

Tabla 3.31: Estadística Descriptiva Resumen Data Total

Estadístico	EUR	LIB	SIL	GOL	COP	BRE	WTI	GAS	CSA	CEU
Mean	-3,5088	-8,4496	0,0002	0,0003	-0,0002	-0,0002	-0,0002	-0,0004	2,1272	-0,0001
Median	7,3771	0,0000	0,0000	0,0003	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
Maximum	0,0372	0,0304	0,1828	0,1039	0,1173	0,1271	0,1641	0,2677	0,2384	0,1641
Minimum	-0,0280	-0,0393	-0,1869	-0,0888	-0,1032	-0,1095	-0,1307	-0,1489	-0,2073	-0,2286
Std. Dev.	0,0064	0,0059	0,0229	0,0121	0,0186	0,0218	0,0244	0,0314	0,0158	0,0154
Skewness	0,1020	-0,4206	-0,4219	-0,2365	-0,1226	0,0144	0,1762	0,7635	0,5267	-1,5620
Kurtosis	5,2110	6,3895	11,9290	8,5992	6,2178	6,6689	7,9176	8,5433	46,9881	44,4992
Jarque-Bera	524,7	1.297,9	8.560,0	3.360,1	1.108,3	1.432,5	2.586,7	3.518,1	206.029,6	184.307,6
Sum	-0,0896	-0,2158	0,4399	0,7002	-0,4406	-0,4558	-0,4935	-1,0106	0,0543	-0,3304
Sum Sq. Dev.	0,1046	0,0887	1,3356	0,3758	0,8825	1,2165	1,5195	2,5156	0,6351	0,6090
Observations	2.554	2.554	2.554	2.554	2.554	2.554	2.554	2.554	2.554	2.554

Test de Estacionariedad Data Total

A continuación se presentan los test ADF de cada una de las series resumidos en una sola tabla, el detalle se puede encontrar en el anexo A.1.

Tabla 3.32: Test ADF resumido para todas las series Data Total

SERIES	t-statistic	p-value
EUR	-50.05225	0.0000
LIB	-48.26120	0.0000
SIL	-55.54711	0.0000
GOL	-50.15923	0.0000
COP	-54.45962	0.0000
BRE	-54.08923	0.0000
WTI	-53.14102	0.0000
GAS	-54.73156	0.0000
CSA	-50.23821	0.0000
CEU	-48.81137	0.0000
Test Critical Values	1 %	-3.961638
	5 %	-3.411568
	10 %	-3.127650

Dado los resultados anteriores, analizando el p – *value* podemos resumir que todas las series de retornos de commodities son estacionarias.

Test de Heterocedasticidad Data Total

A continuación se presenta el resumen de los test de heterocedasticidad para cada una de las series de commodities. El detalle del test se puede encontrar en el anexo A.2.

Tabla 3.33: Resumen test de Levene Data Total

RESUMEN			
Serie	t-Statistic	p-value	Resultado
EUR	4,039605	0,0071	Heterocedástico
LIB	2,664042	0,0464	Heterocedástico
SIL	18,27267	0,0000	Heterocedástico
GOL	2,930401	0,0197	Heterocedástico
COP	1,741825	0,1217	Homocedástico
BRE	3,306208	0.0056	Heterocedástico
WTI	1,000773	0,3914	Homocedástico
GAS	0,330372	0,8577	Homocedástico
CSA	0,497124	0,7786	Homocedástico
CEU	6,628918	0,0000	Heterocedástico

3.1.12. Resumen Data Pre Crisis

Estadística Descriptiva Data Pre Crisis

A continuación se presenta la estadística descriptiva para todas las series para el periodo Data Pre Crisis.

Tabla 3.34: Estadística Descriptiva Resumen Pre Crisis

	EUR	LIB	SIL	GOL	COP	BRE	WTI	GAS	CSA	CEU
Mean	0,0004	0,0002	0,0007	0,0007	-0,0004	0,0006	0,0006	0,0007	0,0018	0,0018
Median	0,0003	0,0003	0,0015	0,0008	0,0000	0,0013	0,0006	0,0000	0,0000	0,0000
Maximum	0,0114	0,0106	0,0559	0,0307	0,0600	0,0493	0,0737	0,2496	0,0635	0,1366
Minimum	-0,0145	-0,0170	-0,0708	-0,0351	-0,0830	-0,0504	-0,0479	-0,1489	-0,0695	-0,0445
Std, Dev,	0,0039	0,0043	0,0181	0,0108	0,0201	0,0166	0,0186	0,0368	0,0139	0,0127
Skewness	-0,1669	-0,3711	-0,6895	-0,3394	-0,2077	-0,1559	0,0777	0,8377	0,4573	3,8538
Kurtosis	3,3540	3,9025	4,4804	3,6137	3,7596	3,0586	3,4145	9,3392	7,2217	39,7717
Jarque-Bera	3,749	21,617	64,808	13,257	11,868	1,594	3,103	680,713	295,444	22.349,790
Probability	0,1534	0,0000	0,0000	0,0013	0,0026	0,4506	0,2119	0,0000	0,0000	0,0000
Sum	0,1531	0,0874	0,2496	0,2601	-0,1656	0,2120	0,2427	0,2577	0,6699	0,6924
Sum Sq, Dev,	0,0058	0,0071	0,1242	0,0446	0,1532	0,1044	0,1316	0,5139	0,0728	0,0612
Observations	380	380	380	380	380	380	380	380	380	380

Test de Estacionariedad Data Pre Crisis

A continuación se presentan los test ADF de cada una de las series resumidos en una sola tabla para el periodo Pre Crisis.

Tabla 3.35: Test ADF resumido para todas las series Data Pre Crisis

RESUMEN	t-Statistic	p-value
EUR	-19,41408	0,0000
LIB	-18,68919	0,0000
SIL	-20,40886	0,0000
GOL	-20,76261	0,0000
COP	-20,09373	0,0000
BRE	-21,40658	0,0000
WTI	-21,24038	0,0000
GAS	-19,85996	0,0000
CSA	-19,09982	0,0000
CEU	-21,99492	0,0000
Test Critical Values	1 %	-3,982457
	5 %	-3,421725
	10 %	-3,133663

Dado los resultados anteriores, analizando el p – *value* podemos resumir que todas las series de retornos de commodities son estacionarias.

Test de Heterocedasticidad Data Pre Crisis

A continuación se presenta el resumen de los test de heterocedasticidad para cada una de las series de commodities en periodo Data Pre Crisis.

Tabla 3.36: Resumen test de Levene Pre Crisis

RESUMEN			
SERIE	t-Statistic	p-value	Resultado
EUR	1,72357	0,1617	Homocedástico
LIB	1,859973	0,1359	Homocedástico
SIL	3817651	0,0102	Heterocedástico
GOL	1,064419	0,3641	Homocedástico
COP	0,7898	0,5002	Homocedástico
BRE	1,681916	0,1380	Homocedástico
WTI	0.442570	0,6427	Homocedástico
GAS	1,107593	0,3526	Homocedástico
CSA	1,155013	0,3268	Homocedástico
CEU	0,704787	0,5496	Homocedástico

3.1.13. Resumen Data Post Crisis

Estadística Descriptiva Data Post Crisis

A continuación se presenta la estadística descriptiva para todas las series para el periodo Data Post Crisis.

Tabla 3.37: Estadística Descriptiva Resumen Post Crisis

	EUR	LIB	SIL	GOL	COP	BRE	WTI	GAS	CSA	CEU
Mean	-0,0001	0,0000	0,0003	0,0002	0,0003	0,0000	0,0000	-0,0005	-0,0002	-0,0003
Median	0,0001	0,0000	0,0000	0,0003	0,0000	-0,0001	0,0000	0,0000	0,0000	0,0000
Maximum	0,0372	0,0201	0,1736	0,0477	0,0897	0,1042	0,1314	0,2677	0,1115	0,1093
Minimum	-0,0265	-0,0393	-0,1869	-0,0888	-0,0782	-0,0970	-0,1307	-0,1193	-0,2073	-0,2286
Std, Dev,	0,0064	0,0057	0,0221	0,0110	0,0164	0,0204	0,0229	0,0305	0,0124	0,0126
Skewness	0,0449	-0,3233	-0,4919	-0,5591	0,1304	0,1048	0,1275	0,8367	-1,1435	-3,1875
Kurtosis	4,6046	5,2888	12,2596	7,2357	5,5393	6,1429	7,2168	8,4097	59,3798	71,3652
Jarque-Bera	205	450	6.907	1.528	519	790	1.421	2.554	253.651	375.583
Probability	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
Sum	-0,1999	0,0020	0,5037	0,3875	0,5060	0,0542	0,0303	-0,9824	-0,3880	-0,5850
Sum Sq, Dev,	0,0781	0,0610	0,9350	0,2315	0,5156	0,7988	1,0015	1,7815	0,2936	0,3032
Observations	1.912	1.912	1.912	1.912	1.912	1.912	1.912	1.912	1.912	1.912

Test de Estacionariedad Data Post Crisis

A continuación se presentan los test ADF de cada una de las series resumidos en una sola tabla para el periodo Post Crisis.

Tabla 3.38: Test ADF resumido para todas las series Data Post Crisis

RESUMEN	t-Statistic	p-value
EUR	-44,15506	0,0000
LIB	-43,07725	0,0000
SIL	-48,41695	0,0000
GOL	-48,17473	0,0000
COP	-47,01525	0,0000
BRE	-46,20478	0,0000
WTI	-45,41721	0,0000
GAS	-48,17473	0,0000
CSA	-32,64016	0,0000
CEU	-31,63846	0,0000
Test Critical Values	1 %	-3,962851
	5 %	-3,412161
	10 %	-3,128002

Dado los resultados anteriores, analizando el $p - value$ podemos resumir que todas las series de retornos de commodities son estacionarias.

Test de Heterocedasticidad Data Post Crisis

A continuación se presenta el resumen de los test de heterocedasticidad para cada una de las series de commodities en periodo Data Pre Crisis.

Tabla 3.39: Resumen test de Levene Post Crisis

RESUMEN			
SERIE	t-Statistic	p-value	Resultado
EUR	3,207136	0,0223	Heterocedástico
LIB	2,281725	0,0774	Homocedástico
SIL	9,034793	0,0000	Heterocedástico
GOL	5,716118	0,0033	Heterocedástico
COP	1,023873	0,3810	Homocedástico
BRE	1,887321	0,1100	Homocedástico
WTI	2,013159	0,1101	Homocedástico
GAS	1,302984	0,2667	Homocedástico
CSA	0,538602	0,6559	Homocedástico
CEU	0,574287	0,6813	Homocedástico

3.2. Metodología

Las metodologías a aplicar en este estudio son el HS (Historical Simulation), CAViaR (Conditional Autoregressive Value at Risk) y EGARCH (xponential, Generalized, Autoregressive, Conditional Heteroscedasticity), cada metodología representa un tipo de cálculo del VaR: no paramétrico, semi-paramétrico y paramétrico.

3.2.1. HS: Historical Simulation.

La Simulación Histórica usará los retornos del índice observado, ya sean monedas o commodities, en un período de tiempo con el fin de determinar la serie de cambios en su valor, siendo el VaR de ese período igual al percentil de la distribución de retornos dado un porcentaje de confianza requerido, en este caso un 95 %. Todo lo anterior, se realiza mediante ventanas móviles de 254 días, lo que es equivalente a un año aproximadamente.

Para estimar el VaR mediante Simulación Histórica (HS) se deben ordenar los retornos

de menor a mayor:

$$y_1 < y_2 < y_3 < y_4 < \dots < y_n$$

donde y_1 es el retorno menor y y_2 el segundo menor y así sucesivamente.

Entonces un estimador del VaR por Simulación Histórica (HS), en valor absoluto, para un nivel de confianza p , viene dado por:

$$VaR_{HS}(p) = -y_j \quad (3.2)$$

donde j es el número entero que satisface lo siguiente:

$$\frac{j-1}{n} < 1-p < \frac{j}{n} \quad (3.3)$$

donde n es el tamaño de la muestra.

3.2.2. CAViaR: Conditional Autoregressive Value at Risk.

El modelo CAViaR formulado por Engle y Manganelli (1999), se centra en la modelación del percentil de probabilidad, por lo tanto, para su ejecución se debe tener en cuenta que la rentabilidad de los índices tienden a agruparse a través del tiempo, es decir, presentan correlación entre ellas. Los parámetros de este modelo son estimados vía regresiones por cuantiles, como fue presentado por Koenker y Bassett (1978). Donde la definición general del CAViaR es:

$$VaR_t = f(x_t, \beta_\theta) = \beta_0 + \sum_{i=1}^p \beta_i VaR_{t-i} + l(\beta_{p+1}, \dots, \beta_{p+q}; \Omega_{t-1}) \quad (3.4)$$

donde Ω_{t-1} es el conjunto total de información disponible en t .

Se debe destacar que en la mayoría de los casos prácticos esta expresión se puede linealizar, quedando expresada de una forma más sencilla:

$$VaR_t = \beta_0 + \beta_1 VaR_{t-1} + l(\beta_2, Y_{t-1}, VaR_{t-1}) \quad (3.5)$$

El término autoregresivo $\beta_1 VaR_{t-1}$ asegura que los cambios del VaR sean suaves a través del tiempo, mientras que $l(\beta_2, Y_{t-1}, VaR_{t-1})$ muestra la relación entre el nivel del VaR_t y el de y_{t-1} , es decir, mide lo que debe cambiar el VaR en función de la nueva información disponible en Y .

3.2.3. EGARCH: Exponential, Generalized, Autoregressive, Conditional Heteroscedasticity.

Si bien es cierto, Engle y Manganelli (2001) plantean que es más recomendable utilizar un GARCH (1,1), se opta por utilizar un EGARCH propuesto por Nelson (1991), ya que así se puede incorporar el efecto de la asimetría, vease las siguientes ecuaciones:

$$r_t = \sum_{i=1}^s \alpha_i r_{t-i} + \epsilon_t \quad (3.6)$$

$$\log(\sigma_t^2) = \gamma + \sum_{j=1}^p \beta_j \left| \frac{\epsilon_{t-j}}{\sigma_{t-j}} \right| + \sum_{k=1}^p \delta_k \frac{\epsilon_{t-k}}{\sigma_{t-k}} + \sum_{l=1}^q \varphi_l \ln(\sigma_{t-1}^2) \quad (3.7)$$

En general, el proceso y_t sigue un modelo EGARCH(p, q) si:

$$y_t = \sigma_t \epsilon_t$$

donde ϵ_t se supone con una distribución normal y

$$\log(\sigma_t^2) = \omega + \sum_{j=1}^p \beta_j \log(\sigma_{t-j}^2) + \sum_{i=1}^q \left[\alpha_i \left(\left| \frac{y_{t-i}}{\sigma_{t-i}} \right| - \sqrt{\frac{2}{\pi}} \right) - \gamma \frac{y_{t-i}}{\sigma_{t-i}} \right] \quad (3.8)$$

3.3. Backtesting

El *backtest* en tres diferentes el UC (*Unconditional Coverage*), IND (*Independence*) y CC (*Conditional Coverage*). El test CC engloba a los otros dos, sin embargo, la ventaja que tiene la ejecución de los tres test es que si el CC se rechaza se puede ver si se rechazó por UC

o por IND. Estos test requieren del no rechazo de la hipótesis nula, por lo tanto requieren de un valor p^9 mayor al valor de seguridad especificado. Otro parámetro a considerar es el número de polinomios utilizados en el test (P). Este número es importante para determinar si la hipótesis se rechazan o no, dado que mientras más alto es hay un mayor grado de polinomios en el estadístico y este se hace más exacto. Para este estudio, el valor de p a utilizar es 10 % y el número de polinomios es seis; valores utilizados por Candelon *et al.*(2011)¹⁰.

Sea r_t el retorno de un activo en el período t y $VaR_{t|t-1}(\alpha)$ la proyección del VaR *ex-ante* obtenida condicionalmente con el set de información F_{t-1} y para un α % como tasa de cobertura. Si el modelo del VaR es válido, entonces se debe cumplir la siguiente ecuación:

$$Pr[r_t < VaR_{t|t-1}(\alpha)] = \alpha, \forall t \in \mathbb{Z} \quad (3.9)$$

Sea $I_t(\alpha)$ la variable *hit o golpe* asociada con la observación *ex-post* de un α % de violación del VaR en el período t , es decir:

$$I_t(\alpha) = \begin{cases} 1 & \text{si } r_t < VaR_{t|t-1}(\alpha) \\ 0 & \text{en otro caso} \end{cases} \quad (3.10)$$

De esta variable, Christoffersen (1998) determina que las predicciones del VaR son válidas si y solo si, la secuencia de violaciones $\{I_t(\alpha)\}$ satisface las siguientes dos hipótesis.

- Hipótesis de Cobertura Incondicional (UC): la probabilidad de que un retorno *ex-post* sea superior a la proyección del VaR debe ser igual a la tasa de cobertura α .

$$Pr[I_t(\alpha) = 1] = \mathbb{E}[I_t(\alpha)] = \alpha \quad (3.11)$$

- Hipótesis de Independencia (IND): las violaciones observadas del VaR en dos diferentes fechas para la misma tasa de cobertura deben estar distribuidas de forma

⁹Es la probabilidad de obtener al menos un resultado similar al que se obtiene al calcular el estadístico (Greene, 2002).

¹⁰Werner Kristjanpoller y Andrés Barahona (2014). *Backtesting del valor en riesgo para los mercados bursátiles y de divisas latinoamericanas*.

independiente. Formalmente la variable $I_t(\alpha)$ asociada con las violaciones del VaR en el período t para una tasa de cobertura α % debería ser independiente de la variable $I_{t-k}(\alpha)$, $\forall k \neq 0$. En otras palabras, las violaciones pasadas del VaR no deberían influir en las violaciones actuales o futuras.

Cuando las hipótesis UC y IND son validas simultáneamente, se dice que las proyecciones del VaR tienen una correcta cobertura condicional (CC) y el proceso de las violaciones del VaR es una martingala con:

$$\mathbb{E}[I_t(\alpha) - \alpha | \Omega_{t-1}] = 0 \quad (3.12)$$

Siempre y cuando la secuencia de violaciones $\{I_t(\alpha)\}$ sea un proceso aleatorio de acuerdo a la distribución de Bernoulli con una probabilidad de éxito igual α . Sin embargo, como lo sugiere Christoffersen and Pelletier (2004), existe otra manera de testearlo, basado en la dependencia de la duración entre dos violaciones consecutivas. Formalmente, se denota d_i como la duración entre violaciones consecutivas:

$$d_i = t_i - t_{i-1} \quad (3.13)$$

Donde t_i denota la fecha de la violación i -ésima. Bajo la hipótesis de CC, la variable duración $\{d_i\}$ sigue el patrón de una distribución geométrica con parámetro α y una función de probabilidad dada por:

$$f(d; \alpha) = \alpha(1 - \alpha)^{d-1} \quad d \in \mathbb{N}^*. \quad (3.14)$$

La distribución geométrica caracteriza la propiedad de independencia de los valores pasados de la secuencia de violaciones $\{I_t(\alpha)\}$ lo que significa que la probabilidad de observar un violación en el presente no depende del numero de días que transcurrieron desde la última violación.

El *Backtest* aplicado se basa en el Método Generalizado de los Momentos (GMM, *Generalized Method of Moments*) y polinomios ortonormales, este test esta alineado con los procedimientos de testeo de distribuciones propuesto por Bontemps y Meddahi (2005,2006).

Este acercamiento presenta varias ventajas.

- Es extremadamente simple de implementar, dado que consiste en un simple GMM test condicional de momentos.
- Permite un adecuado tratamiento del problema asociado con parámetros de incertidumbre.
- La elección de momento condicional nos permite desarrollar test separados para las hipótesis UC, IND y CC.

Por otro lado, los Polinomios Ortonormales asociados con la distribución geométrica (3.6) son definidos como:

Los polinomios ortonormales asociados a una distribución geométrica con una probabilidad de éxito β son definidos por la siguiente relación recursiva $\forall d \in \mathbb{N}^$.*

$$M_{j+1}(d; \beta) = \frac{(1 - \beta)(2j + 1) + \beta(j - d + 1)}{(j + 1) \sqrt{1 - \beta}} M_j(d; \beta) - \left(\frac{j}{j + 1} \right) M_j(d; \beta) \quad (3.15)$$

para cualquier $j \in \mathbb{N}$, con $M_{-1}(d; \beta) = 0$ y $M_0(d; \beta) = 1$. Si la verdadera distribución de D es geométrica con una probabilidad de éxito β , entonces:

$$\mathbb{E}[M_j(d; \beta)] = 0 \quad \forall j \in \mathbb{N}^*, \forall d \in \mathbb{N}^*. \quad (3.16)$$

Este procedimiento de backtest basado en la duración utiliza esta condición de momentos. Más precisamente, se define $\{d_1; \dots; d_N\}$ como una secuencia de duraciones entre N violaciones al VaR, las cuales se calculan a través de la secuencia de variables *hit* $\{I_t(\alpha)\}_{t=1}^T$. Bajo el supuesto de cobertura condicionada, la duración d_i , $i = 1, \dots, N$ es independiente e idénticamente distribuida (i.i.d) y tiene una distribución geométrica con una probabilidad de éxito igual a la tasa de cobertura α . Por lo tanto, la hipótesis nula de CC puede ser expresada como:

$$H_{0,CC} : \mathbb{E} [M_j(d_i; \alpha)] = 0, \quad j = \{1, \dots, p\}. \quad (3.17)$$

donde p denota el número de momentos condicionados.

Esto permite testear separadamente las hipótesis UC y IND. Así la hipótesis nula para UC puede ser expresada como:

$$H_{0,UC} : \mathbb{E} [M_1(d_i; \alpha)] = 0. \quad (3.18)$$

De hecho, bajo UC, el valor esperado de la variable duración es igual a $1/\alpha$. Dado que $M_1(d, \alpha) = (1 - \alpha d) / \sqrt{1 - \alpha}$. Por lo tanto, es sencillo verificar que la condición $\mathbb{E} [M_1(d_i; \alpha)] = 0$ es equivalente a la condición de UC $\mathbb{E}(d_i) = 1/\alpha, \forall d_i$.

Luego se puede derivar un test separado para la hipótesis de IND. Lo cual consiste en testear la hipótesis de distribución geométrica (implica la ausencia de dependencia) con una probabilidad de éxito igual a β , donde β denota la verdadera tasa de violación, que no es necesariamente igual a la tasa de cobertura α . Este supuesto de independencia puede ser expresado con la siguiente condición de momento.

$$H_{0,IND} : \mathbb{E} [M_j(d_i; \beta)] = 0 \quad j = \{1, \dots, p\}. \quad (3.19)$$

En este caso, el valor esperado de la variable duración es igual a $1/\beta$ así como el primer polinomio $M_1(d; \beta)$ es incluido en el ser de momentos condicionados. Por lo tanto, bajo $H_{0,IND}$ la duración entre dos violaciones consecutivas tiene una distribución geométrica y la hipótesis UC no es válida si $\beta \neq \alpha$.

De acuerdo a lo presentado por Bontemps (2006), los polinomios ortonormales presentan la ventaja que su matriz asintótica de varianzas y covarianzas es conocida. De hecho, en un contexto de i.i.d, los momentos son asintóticamente independientes con varianza unitaria. Como resultado, la matriz de pesos óptimos bajo los criterios del método generalizado de momentos (GMM) es simplemente una matriz identidad, y la implementación del *backtesting* se vuelve sencilla. Donde $J_{CC}(p)$ denota la prueba estadística de CC asociada a los primeros p polinomios ortonormales. Entonces Suponiendo que el proceso de duración $(d_i : 1 \leq i)$ es estacionario y ergódico la hipótesis nula de la cobertura condicionada $J_{CC}(p)$ se escribe como:

$$J_{CC}(p) = \left(\frac{1}{\sqrt{N}} \sum_{i=1}^N M(d_i; \alpha) \right)^T \left(\frac{1}{\sqrt{N}} \sum_{i=1}^N M(d_i; \alpha) \right) \xrightarrow[N \rightarrow \infty]{d} \chi^2(p). \quad (3.20)$$

donde $M(d_i; \alpha)$ representa un vector $(p, 1)$, cuyos componentes son los polinomios ortonormales $M_j(d_i; \alpha)$ para $j = 1, \dots, p$ y α indica la tasa de cobertura $\alpha \%$.

El estadístico de prueba para la hipótesis UC, J_{UC} , es obtenido como un caso especial del estadístico J_{CC} , cuando sólo se considera el primer polinomio ortonormal, es decir, cuando $M(d_i; \alpha) = M_1(d_i; \alpha)$. Por lo tanto, J_{UC} es equivalente a $J_{CC}(1)$ obteniéndose la siguiente expresión:

$$J_{UC}(p) = \left(\frac{1}{\sqrt{N}} \sum_{i=1}^N M(d_i; \beta) \right)^2 \xrightarrow[N \rightarrow \infty]{d} \chi^2(1). \quad (3.21)$$

Finalmente, el estadístico para IND , denotado como J_{IND} , puede ser expresado como:

$$J_{IND}(p) = \left(\frac{1}{\sqrt{N}} \sum_{i=1}^N M(d_i; \beta) \right)^T \left(\frac{1}{\sqrt{N}} \sum_{i=1}^N M(d_i; \beta) \right) \xrightarrow[N \rightarrow \infty]{d} \chi^2(p). \quad (3.22)$$

donde $M(d_i; \beta)$ denota un vector $(p, 1)$ cuyos componentes son los polinomios ortonormales $M_j(d_i; \beta)$ para $j = 1, \dots, p$ evaluada para una probabilidad de éxito igual β .

Sin embargo, la tasa de violaciones del VaR β (la cual puede ser diferente de la tasa de cobertura, α , fijada por el administrador de riesgo en el modelo) es generalmente desconocida. Por lo tanto, el estadístico de prueba de independencia debe estar basado en polinomios ortonormales que dependen de la estimación de estos parámetros, es decir, en vez de tener $M_j(d_i; \beta)$ donde β es desconocido, se debe utilizar $M_j(d_i; \hat{\beta})$, donde $\hat{\beta}$ denota el estimador consistente de N raíces cuadradas de β . Es conocido que al reemplazar el verdadero valor de β por su estimador $\hat{\beta}$ puede cambiar la distribución asintótica del estadístico de GMM. Sin embargo, Bontemps (2006) demostró que la distribución asintótica permanece inalterada si los momentos pueden ser expresados como una proyección sobre la ortogonal de los datos. Así, se puede concluir que la distribución asintótica del estadístico de GMM, $J_{IND}(p)$, basado en $M_j(d_i; \hat{\beta})$ es similar a la basada en $M_j(d_i; \beta)$.

$$J_{IND}(p) = \left(\frac{1}{\sqrt{N}} \sum_{i=1}^N M(d_i; \hat{\beta}) \right)^T \left(\frac{1}{\sqrt{N}} \sum_{i=1}^N M(d_i; \hat{\beta}) \right) \xrightarrow[N \rightarrow \infty]{d} \chi^2(p-1). \quad (3.23)$$

donde $M(d_i; \hat{\beta})$ denota un vector $(1, p)$ definido como $(M_1(d_i; \hat{\beta}) \dots M_p(d_i; \hat{\beta}))$. Se debe notar que en este caso, el primer polinomio $M_1(d_i; \hat{\beta})$ es estrictamente proporcional a los datos utilizados para definir el estimador de máxima verosimilitud $\hat{\beta}$ y así $M_1(d_i; \hat{\beta}) = 0$, por lo tanto, los grados de libertad del estadístico J deben ser ajustados.

4 | Análisis de Resultados

Para un mejor análisis y comprensión de los resultados de esta tesis se debe tener en consideración la estadística descriptiva para cada período en estudio, Data Total (julio 2006 - abril 2016) con 2.554 registros de retornos, Data Período Pre Crisis (julio 2006 - diciembre 2007) con 380 registros de retornos y Data Período Post Crisis (enero 2009 - abril 2016) con 1.912 registros de retornos, los cuales fueron presentados en la Sección Data y Metodología.

4.1. Período Data Total (Julio 2006 - Abril 2016)

Para el Periodo Data Total (tabla 3.31) se puede apreciar una rentabilidad promedio negativa en la mayoría de los commodities, excepto para los siguientes: Plata (SIL), Oro (GOL) y Carbón de Sudáfrica (CSA) donde su rentabilidad promedio fue positiva. Además se observa un comportamiento leptocúrtico en todos los índices, siendo mayormente pronunciado en el caso de la Plata (SIL), Carbón de Sudáfrica (CSA) y Carbón de Europa (CEU). Por otro lado, se observa una asimetría positiva en cinco de los índices, Tipo de Cambio Euro/Dólar (EUR), Petróleo Brent (BRE), Petróleo WTI (WTI), Gas Natural (GAS) y Carbón de Sudáfrica (CSA), y una asimetría negativa en los otros cinco índices, Tipo de Cambio Libra/Dólar (LIB), Plata (SIL), Oro (GOL), Cobre (COP) y Carbón de Europa (EUR).

Los resultados del *backtest* aplicados a la proyección realizada por los diferentes modelos; HS, GARCH y CAViaR para el período Data Total se presentan en el siguiente cuadro. Se debe destacar que estos *test* requieren del no rechazo de la hipótesis nula, por lo tanto requieren de un *p-value* mayor al valor de seguridad especificado, en este caso 5 %.

Tabla 4.1: Modelos válidos para commodities analizados en total data.

Commodities	Modelos
EUR	Caviar
LIB	Caviar
SIL	
GOL	Caviar
COP	Caviar
BRE	Caviar
WTI	Caviar
GAS	Caviar
CSA	Caviar
CEU	Caviar

Se puede apreciar que de los diez commodities, nueve presentan un modelo válido, el CAViaR es el mejor modelo de ajuste, además se observa que la Plata (SIL) no tuvo modelo válido en su proyección del VaR, lo que se puede explicar con su estadística descriptiva, ya que este commodity presenta, simultáneamente, una de las mayores volatilidades y asimetría.

Tabla 4.2: Mínimos p -valor para cada una de las pruebas realizadas, total data.

Commodities	UC	IND	CC
EUR			
HS	0,2936	0,0003	0,0009
GARCH	0,0001	0,0171	0,0016
CAVIAR	0,7425	0,5709	0,7469
LIB			
HS	0,2954	0,0021	0,0055
GARCH	0,0001	0,3885	0,0036
CAVIAR	0,917	0,3585	0,5447
SIL			
HS	0,6174	0,0007	0,001
GARCH	0,2037	0,0045	0,0026
CAVIAR	0,4199	0,006	0,0045
GOL			
HS	0,665	0,0006	0,0014

Tabla 4.2: Continuación...

Commodities	UC	IND	CC
GARCH	0,0412	0,0406	0,1143
CAVIAR	0,3213	0,971	0,7963
COP			
HS	0,1962	0,0002	0,0001
GARCH	0,1188	0,0002	0,0008
CAVIAR	0,8108	0,5396	0,6772
BRE			
HS	0,0403	0,0001	0,0012
GARCH	0,0664	0,0008	0,0067
CAVIAR	0,7277	0,9089	0,9648
WTI			
HS	0,0591	0,0005	0,0028
GARCH	0,1791	0,0016	0,0068
CAVIAR	0,6598	0,5243	0,74
GAS			
HS	0,5709	0,0041	0,0086
GARCH	0,0164	0,6185	0,0683
CAVIAR	0,8245	0,3832	0,5834
CSA			
HS	0,9093	0,0056	0,0109
GARCH	0,0001	0,1263	0,002
CAVIAR	0,8887	0,4239	0,618
CEU			
HS	0,8235	0,004	0,0082
GARCH	0,0034	0,0057	0,0017
CAVIAR	0,7572	0,7938	0,9065

Para este periodo considerando la Data Total, podemos desprender del cuadro anterior los test que llevaron a rechazar los modelos, ya sea HS, GARCH o CAVIAR. Para el caso del tipo de cambio Euro (EUR), se aprecia que en el modelo de HS se rechazó la hipótesis IND y no por la hipótesis UC, lo que indica que para el caso del EUR los *hit* o violaciones no se distribuyen de forma independiente, en el modelo de ajuste GARCH se rechazaron ambas hipótesis.

Para el caso del tipo de cambio Libra (LIB) podemos desprender que para el modelo de HS se rechazó también la hipótesis IND, sin embargo, para el caso del GARCH solo se rechazó la hipótesis UC. Si bien es cierto, son dos tipos de cambios la LIB es mucho más

asimétrica que el EUR, aun cuando, ambos indicadores presentan baja volatilidad.

Respecto de la plata (SIL) se rechazó la hipótesis IND en todos los modelos, no generando algún modelo válido en su proyección del VaR, lo que se puede explicar por su estadística descriptiva donde presenta una alta asimetría y volatilidad.

El oro (GOL) obtuvo como modelo válido el CAViaR, rechazando la hipótesis IND en el modelo de HS, sin embargo para el modelo GARCH fue levemente rechazado en ambas hipótesis, lo que deja al GOL dependiendo del grado de significancia que se exija, en este caso 5 %.

En la serie del Cobre (COP) se rechazó la hipótesis IND en ambos modelos, HS y GARCH, no rechazando la hipótesis IND y UC en el caso del modelo CAViaR, modelo válido para este commodity. Lo mismo sucede con el petróleo Brent (BRE) y WTI, era de esperar que estos últimos tuvieran el mismo comportamiento dada su vinculación en el mercado operacional.

Para el caso del Gas Natural (GAS) el modelo de HS es rechazado por hipótesis IND y el modelo GARCH por hipótesis UC, obteniendo como modelo válido el CAViaR.

Respecto del commodity Carbón de Sudáfrica (CSA) el modelo HS fue rechazado por hipótesis IND, mientras que el modelo GARCH por hipótesis UC, así mismo en el mercado de Carbón de Europa (CEU) el modelo HS fue rechazado por hipótesis IND, mientras que el modelo GARCH por ambas hipótesis IND y UC.

4.2. Período Pre Crisis (Julio 2006 - Diciembre 2007)

Para el Período Data Pre Crisis (tabla 3.34) se puede apreciar una rentabilidad promedio positiva en casi todos los commodities, excepto para el Cobre (COP) donde su rentabilidad promedio fue negativa. Además se observa un comportamiento leptocúrtico en todos los índices, siendo mayormente pronunciado en el caso de Gas Natural (GAS), Carbón de Sudáfrica (CSA) y Carbón de Europa (CEU). Por otro lado, se observa una asimetría positiva en cuatro de los índices, Petróleo WTI (WTI), Gas Natural (GAS), Carbón de Sudáfrica (CSA) y Carbón de Europa (CEU) y una asimetría negativa en los otros seis índices, Tipo de Cambio Euro/Dólar (EUR), Tipo de Cambio Libra/Dólar (LIB), Plata (SIL),

Oro (GOL), Cobre (COP) y Petróleo Brent (BRE).

Tabla 4.3: Modelos válidos para commodities analizados en Pre Crisis.

Commodities	Modelos
EUR	HS / Garch / Caviar
LIB	HS / Garch / Caviar
SIL	HS / Caviar
GOL	HS / Garch
COP	HS / Garch / Caviar
BRE	HS / Caviar
WTI	HS / Caviar
GAS	Caviar
CSA	HS / Caviar
CEU	Garch / Caviar

De la tabla anterior podemos apreciar los modelos válidos para cada uno de los commodities en el período Data Pre Crisis, debemos recordar que es un período de 380 observaciones, prácticamente un año, que no es significativo para analizar los comportamientos de commodities en el largo plazo, dado que los resultados podrían explicarse por falta de violaciones al modelo debido a la poca cantidad de registros, sin embargo, revisaremos las implicaciones de los resultados en corto plazo.

Tabla 4.4: Mínimos p -valor para cada una de las pruebas realizadas, Pre Crisis.

Commodities	UC	IND	CC
EUR			
HS	0,3379	0,4082	0,5689
GARCH	0,5707	0,2080	0,2211
CAVIAR	0,1454	0,1763	0,1939
LIB			
HS	0,1259	0,8999	0,4153
GARCH	0,0696	0,1542	0,1273
CAVIAR	0,0746	0,6860	0,2406
SIL			
HS	0,9007	0,8005	0,9308
GARCH	0,0097	0,7847	0,0254

Tabla 4.4: Continuación...

Commodities	UC	IND	CC
CAVIAR	0,7988	0,4782	0,6269
GOL			
HS	0,8101	0,2660	0,4563
GARCH	0,5156	0,6859	0,8135
CAVIAR	0,7865	0,0316	0,0459
COP			
HS	0,9890	0,7653	0,9081
GARCH	0,4852	0,8964	0,9180
CAVIAR	0,6611	0,0916	0,1748
BRE			
HS	0,2237	0,6332	0,3155
GARCH	0,0012	0,4471	0,0069
CAVIAR	0,6182	0,6514	0,5304
WTI			
HS	0,4579	0,5248	0,2965
GARCH	0,0115	0,3740	0,0163
CAVIAR	0,7097	0,4412	0,6735
GAS			
HS	0,3952	0,0105	0,1121
GARCH	0,0001	0,4524	0,0009
CAVIAR	0,2161	0,1538	0,0203
CSA			
HS	0,6766	0,4532	0,7051
GARCH	0,0001	0,7774	0,0001
CAVIAR	0,0919	0,0565	0,0060
CEU			
HS	0,6600	0,0146	0,0674
GARCH	1,0000	1,0000	1,0000
CAVIAR	0,0800	0,6390	0,0894

Para el caso de las monedas EUR y LIB, todos los modelos resultaron válidos al no rechazar la hipótesis IND y UC, lo mismo sucede con el Cobre (COP), lo cual se explica por la menor volatilidad de sus retornos, que implicaría una cantidad menos de violaciones al modelo.

Respecto de los siguientes commodities SIL, BRE, WTI y CSA, se puede apreciar que los modelos válidos fueron HS y CAViaR, no validando el GARCH, dado que se rechazó la hipótesis UC en todos los commodities, esto podría indicar un exceso o carencia de

violaciones en el VaR distribuidos independientemente.

Por otro lado, el Oro (GOL) es el único modelo donde el CAViaR no resultó ser válido, siendo rechazado por su hipótesis IND, es decir, donde los *hit* o violaciones no se distribuyen de forma independiente. Sin embargo, los modelos HS y GARCH fueron validados.

Con respecto al Gas Natural (GAS), el modelo CAViaR fue el único modelo donde no se rechazaron las hipótesis IND y UC. Rechazándose la hipótesis IND en el caso de HS y la hipótesis UC en el caso del GARCH. Esto puede explicarse por la alta volatilidad de sus retornos, la mayor para este período y también una alta asimetría.

Por último, el caso del Carbón de Europa (CEU) se tienen dos modelos válidos el GARCH y CAViaR, rechazándose la hipótesis IND en el modelo HS. Este commodity presenta la más alta asimetría de todos y una de las volatilidades más bajas. Sin embargo, para el modelo GARCH presenta cero violaciones lo que indica un comportamiento suave de su rentabilidad.

4.3. Período Post Crisis (Enero 2009 - Abril 2016)

Para el Período Data Post Crisis (tabla 3.37) se puede apreciar una rentabilidad promedio positiva en seis de los commodities, excepto para los siguientes: Tipo de Cambio Euro/Dólar (EUR), Gas Natural (GAS), Carbón de Sudáfrica (CSA) y Carbón de Europa (CEU) donde su rentabilidad promedio fue negativa. Además se observa un comportamiento leptocúrtico en todos los índices, siendo mayormente pronunciado en el caso de Plata (SIL), Carbón de Sudáfrica (CSA) y Carbón de Europa (CEU). Por otro lado, se observa una asimetría positiva en cinco de los índices, Tipo de Cambio Euro/Dólar (EUR), Cobre (COP), Petróleo Brent (BRE), Petróleo WTI (WTI) y Gas Natural (GAS) y una asimetría negativa en los otros cinco índices, Tipo de Cambio Libra/Dólar (LIB), Plata (SIL), Oro (GOL), Carbón de Sudáfrica (CSA) y Carbón de Europa (CEU).

Tabla 4.5: Modelos válidos para commodities analizados en Post Crisis.

Commodities	Modelos
EUR	Garch / Caviar
LIB	Caviar
SIL	
GOL	HS / Garch / Caviar
COP	Caviar
BRE	Garch / Caviar
WTI	Garch / Caviar
GAS	Caviar
CSA	Garch / Caviar
CEU	HS / Garch / Caviar

De la tabla anterior podemos apreciar los modelos válidos para cada uno de los commodities en el período Data Post Crisis, debemos recordar que es un período de 1.912 observaciones, más parecido al período completo. En este período existe un aumento de las volatilidades respecto del período Pre Crisis y por consiguiente el modelo HS se vuelve deficiente y solo aplica para dos de los commodities, GOL y CEU.

Tabla 4.6: Mínimos p -valor para cada una de las pruebas realizadas, Post Crisis.

Commodities	UC	IND	CC
EUR			
HS	0,4066	0,0018	0,0017
GARCH	0,623	0,4497	0,6822
CAVIAR	0,8705	0,9175	0,9738
LIB			
HS	0,2232	0,0358	0,0245
GARCH	0,0028	0,4267	0,0074
CAVIAR	0,5476	0,6569	0,6796
SIL			
HS	0,3641	0,0006	0,0008
GARCH	0,0002	0,0061	0,0004
CAVIAR	0,4003	0,0061	0,0052
GOL			
HS	0,6896	0,1415	0,1998

Tabla 4.6: Continuación...

Commodities	UC	IND	CC
GARCH	0,1514	0,3304	0,2391
CAVIAR	0,7541	0,2982	0,4498
COP			
HS	0,0868	0,0008	0,0003
GARCH	0,0002	0,0903	0,0094
CAVIAR	0,8676	0,9991	0,9998
BRE			
HS	0,4575	0,0151	0,0291
GARCH	0,1975	0,7912	0,4689
CAVIAR	0,9448	0,7312	0,8766
WTI			
HS	0,6934	0,0273	0,0607
GARCH	0,6631	0,7671	0,8241
CAVIAR	0,7956	0,9919	0,9973
GAS			
HS	0,4665	0,0045	0,0077
GARCH	0,0001	0,295	0,0001
CAVIAR	0,9504	0,7794	0,8856
CSA			
HS	0,6497	0,0343	0,0359
GARCH	1,0000	1,0000	1,0000
CAVIAR	0,3314	0,0604	0,1342
CEU			
HS	0,7761	0,4657	0,4637
GARCH	0,1052	0,1266	0,0193
CAVIAR	0,9505	0,9754	0,9929

Para este período considerando la Data Post Crisis, podemos desprender del cuadro anterior los test que llevaron a rechazar los modelos, ya sea HS, GARCH o CAVIAR. Para el caso del tipo de cambio Euro (EUR), se aprecia que en el modelo de HS se rechazó la hipótesis IND y no por la hipótesis UC, lo que indica que para el caso del EUR los *hit* o violaciones no se distribuyen de forma independiente.

Para el caso del tipo de cambio Libra (LIB) podemos desprender que para el modelo de HS se rechazó también la hipótesis IND, sin embargo, para el caso del GARCH solo se rechazó la hipótesis UC. Si bien es cierto, son dos tipos de cambios la LIB es mucho más asimétrica que el EUR, aún cuando, ambos indicadores presentan baja volatilidad.

Respecto del la plata (SIL) se rechazó la hipótesis IND en todos los modelos, no generando algún modelo válido en su proyección del VaR, lo que se puede explicar por su estadística descriptiva donde presenta una alta asimétrica y volatilidad.

El oro (GOL) obtuvo los tres modelos como válidos, curiosamente con una de las menores volatilidades y mayores asimétrica.

En la serie del Cobre (COP) se rechazó la hipótesis IND en el modelo HS y la hipótesis UC en el modelo GARCH, no rechazando la hipótesis IND y UC en el caso del modelo CAViaR, modelo válido para este commodity.

Con respecto al petróleo Brent (BRE) y WTI, era de esperar que estos últimos tuvieran el mismo comportamiento dada su vinculación en el mercado operacional, obtuvieron dos modelos válidos el GARCH y el CAViaR, rechazándose el HS por la hipótesis IND.

Para el caso del Gas Natural (GAS) el modelo de HS es rechazado por hipótesis IND y el modelo GARCH por hipótesis UC, obteniendo como modelo válido el CAViaR.

Respecto del commodity Carbón de Sudáfrica (CSA) el modelo HS fue rechazado por hipótesis IND, mientras que el modelo GARCH presentó cero violaciones, quedando validados el GARCH y CAViaR.

En el mercado de Carbón de Europa (CEU) al igual que el COP, fueron los únicos donde se validaron los tres modelos puestos a prueba.

En General el modelo de simulación histórica fue rechazado mayormente por la hipótesis IND y el modelo GARCH por la hipótesis UC, estableciendo el CAViaR como modelo válido y más eficiente para todos los períodos. Además del análisis de los tres escenarios podría deducirse que existiese un límite para las volatilidades y asimetrías para poder poseer modelos válidos en la proyección de su correspondiente VaR.

5 | Conclusiones

Como se mencionó anteriormente, para realizar un análisis completo y obtener mejores conclusiones, se deben tener en cuenta las estadísticas descriptivas de los commodities en los distintos períodos, Data Total (2.554 observaciones), Data Pre Crisis (380 observaciones) y Data Post Crisis (1.912 observaciones).

Respecto del promedio de rentabilidades para el Período Data Total, el cual incluye el valor de la rentabilidad del año 2008 (*crisis subprime*), se aprecia que solo tres commodities tienen rentabilidades positivas, sin embargo, en el período Pre Crisis nueve commodities presentan rentabilidades promedio positivas y en Post Crisis, solo cuatro indicadores presentan rentabilidades promedio negativas, lo que indica el fuerte impacto que tuvo la crisis en las series históricas de rentabilidades.

Analizando la desviación estándar se puede apreciar que en el período Data Total todos los indicadores presentan mayor volatilidad en las rentabilidad, esto se puede explicar por el mayor número de observaciones y por la consideración del año 2008 en sus registros. Solo el Cobre (COP) y Gas Natural (GAS), presentan menor desviación estándar que el período Pre Crisis. Ahora bien, si se compara el período Pre Crisis con Post Crisis, se puede concluir que solo tres commodities presentan mayores volatilidades en el primer periodo, estos son; Gas Natural (GAS), Carbón de Sudáfrica (CSA) y Carbón de Europa (CEU).

Revisando la asimetría podemos concluir la importancia del año 2008 en los registros, dado que tres commodities cambian de asimetría negativa a asimetría positiva (EUR, COP y BRE) desde el período Pre Crisis al Post Crisis; y otros dos (CSA y CEU) cambian de asimetría positiva a negativa en los mismos períodos, el resto de indicadores mantiene su comportamiento en Data Total. Por último, todos los commodities en todos los períodos presentan un comportamiento leptocúrtico, que nos indica la NO normalidad de las renta-

bilidades, esto también se puede comprobar con el estadístico *Jarque-Bera* en las tablas presentadas en la sección Data y Metodología.

Revisando la siguiente tabla donde están los modelos válidos para cada commodity en cada período de data analizado, podemos concluir que en Pre Crisis el modelo de Simulación Histórica (HS) y el modelo CAViaR son las mejores metodologías para el cálculo de Valor en Riesgo, esto coincide con que el Período Pre Crisis es el que presenta menor volatilidad de todos.

Luego al revisar el periodo Data Post Crisis se puede ver que el método de Simulación Histórica pierde eficiencia, coincidentemente con el aumento de volatilidad de los retornos, donde los mejores modelos en la proyección del VaR resultan ser el GARCH y CAViaR.

Respecto del período con Data Total, incluyendo *crisis subprime*, y analizando los modelos y los resultados obtenidos por las proyecciones con las diferentes metodologías y los *backtest* se puede concluir que el CAViaR es el método más eficiente en la proyección del VaR para todos los commodities y monedas, excepto para la Plata (SIL) donde ningún modelo fue validado, lo que se puede explicar por su alta desviación estándar y asimetría simultáneamente.

Tabla 5.1: Modelos válidos para commodities analizados en todos los periodos

Commodities	Data Total	Pre Crisis	Post Crisis
EUR	Caviar	HS / Garch / Caviar	Garch / Caviar
LIB	Caviar	HS / Garch / Caviar	Caviar
SIL		HS / Caviar	
GOL	Caviar	HS / Garch	HS / Garch / Caviar
COP	Caviar	HS / Garch / Caviar	Caviar
BRE	Caviar	HS / Caviar	Garch / Caviar
WTI	Caviar	HS / Caviar	Garch / Caviar
GAS	Caviar	Caviar	Caviar
CSA	Caviar	HS / Caviar	Garch / Caviar
CEU	Caviar	Garch / Caviar	HS / Garch / Caviar

En la siguiente tabla, se pueden revisar los resultados de los distintos test y ver si los modelos fueron rechazados por hipótesis IND o hipótesis UC. Las tres primeras columnas representan los resultados del período Data Total, las segundas tres columnas, los resultados del período Pre Crisis y las últimas tres columnas el período Post Crisis.

Analizando los resultados de los test en el período Pre Crisis, podemos concluir que el rechazo del modelo GARCH en todos los commodities se realizó a través de la hipótesis UC, lo que se explica por un exceso o carencia de violaciones del VaR para llegar al nivel del 5 % de significancia requerido. Además la metodología de Simulación Histórica (HS) solo fue rechazado en dos commodities (GAS y CEU) en su hipótesis IND, lo que demuestra que los *hit* o violaciones en estos indicadores no se distribuyen independientemente. Por otro lado, se puede apreciar que en el commodity GAS, la única metodología aceptada para el cálculo del VaR es el CAViaR, que coincide con el indicador más volátil, lo que indica que la volatilidad podría sugerir un límite para el no rechazo de las metodologías HS, GARCH y CAViaR.

Posteriormente al analizar el período Post Crisis, se puede apreciar que el rechazo de la metodología Simulación Histórica (HS) se debe a su hipótesis IND en todos los commodities donde no se rechazaron el GARCH y el CAViaR. Luego, analizando los resultados de los test donde el GARCH fue rechazado, se puede observar que nuevamente el *p – value* en la hipótesis UC estuvo bajo el 5 % exigido. Sin embargo el GARCH como el CAViaR fueron aceptados en la mayoría de los commodities como metodología válida para el cálculo del VaR, lo que es congruente entre los modelos paramétricos y semiparamétricos, dado su similitud de cálculos en la componente autoregresiva.

Finalmente al revisar los resultados de los test para la Data Completa se puede observar que la mejor metodología para el cálculo del VaR es el CAViaR, esto coincide con que este período es el de mayor volatilidad y asimetría media. Donde se vuelve apreciar que la metodología Simulación Histórica (HS) se rechaza por su hipótesis IND y la metodología GARCH por su hipótesis UC, lo que demuestra la sensibilidad de las variables a los distintos *backtest*.

Tabla 5.2: Resumen mínimos p -valor para cada una de las pruebas realizadas.

Commodities	UC	IND	CC	UC	IND	CC	UC	IND	CC
EUR									
HS	0,2936	0,0003	0,0009	0,3379	0,4082	0,5689	0,4066	0,0018	0,0017
GARCH	0,0001	0,0171	0,0016	0,5707	0,208	0,2211	0,623	0,4497	0,6822
CAVIAR	0,7425	0,5709	0,7469	0,1454	0,1763	0,1939	0,8705	0,9175	0,9738
LIB									
HS	0,2954	0,0021	0,0055	0,1259	0,8999	0,4153	0,2232	0,0358	0,0245
GARCH	0,0001	0,3885	0,0036	0,0696	0,1542	0,1273	0,0028	0,4267	0,0074
CAVIAR	0,917	0,3585	0,5447	0,0746	0,686	0,2406	0,5476	0,6569	0,6796
SIL									
HS	0,6174	0,0007	0,001	0,9007	0,8005	0,9308	0,3641	0,0006	0,0008
GARCH	0,2037	0,0045	0,0026	0,0097	0,7847	0,0254	0,0002	0,0061	0,0004
CAVIAR	0,4199	0,006	0,0045	0,7988	0,4782	0,6269	0,4003	0,0061	0,0052
GOL									
HS	0,665	0,0006	0,0014	0,8101	0,266	0,4563	0,6896	0,1415	0,1998
GARCH	0,0412	0,0406	0,1143	0,5156	0,6859	0,8135	0,1514	0,3304	0,2391
CAVIAR	0,3213	0,971	0,7963	0,7865	0,0316	0,0459	0,7541	0,2982	0,4498
COP									
HS	0,1962	0,0002	0,0001	0,989	0,7653	0,9081	0,0868	0,0008	0,0003
GARCH	0,1188	0,0002	0,0008	0,4852	0,8964	0,918	0,0002	0,0903	0,0094
CAVIAR	0,8108	0,5396	0,6772	0,6611	0,0916	0,1748	0,8676	0,9991	0,9998
BRE									
HS	0,0403	0,0001	0,0012	0,2237	0,6332	0,3155	0,4575	0,0151	0,0291
GARCH	0,0664	0,0008	0,0067	0,0012	0,4471	0,0069	0,1975	0,7912	0,4689
CAVIAR	0,7277	0,9089	0,9648	0,6182	0,6514	0,5304	0,9448	0,7312	0,8766
WTI									
HS	0,0591	0,0005	0,0028	0,4579	0,5248	0,2965	0,6934	0,0273	0,0607
GARCH	0,1791	0,0016	0,0068	0,0115	0,374	0,0163	0,6631	0,7671	0,8241
CAVIAR	0,6598	0,5243	0,74	0,7097	0,4412	0,6735	0,7956	0,9919	0,9973
GAS									
HS	0,5709	0,0041	0,0086	0,3952	0,0105	0,1121	0,4665	0,0045	0,0077
GARCH	0,0164	0,6185	0,0683	0,0001	0,4524	0,0009	0,0001	0,295	0,0001
CAVIAR	0,8245	0,3832	0,5834	0,2161	0,1538	0,0203	0,9504	0,7794	0,8856
CSA									
HS	0,9093	0,0056	0,0109	0,6766	0,4532	0,7051	0,6497	0,0343	0,0359
GARCH	0,0001	0,1263	0,002	0,0001	0,7774	0,0001	1,0000	1,0000	1,0000
CAVIAR	0,8887	0,4239	0,618	0,0919	0,0565	0,006	0,3314	0,0604	0,1342
CEU									
HS	0,8235	0,004	0,0082	0,6600	0,0146	0,0674	0,7761	0,4657	0,4637
GARCH	0,0034	0,0057	0,0017	1,0000	1,0000	1,0000	0,1052	0,1266	0,0193
CAVIAR	0,7572	0,7938	0,9065	0,0800	0,6390	0,0894	0,9505	0,9754	0,9929

Por último, podemos destacar la importancia de los datos y registro históricos para el cálculo de metodologías que proyecten con un cierto nivel de significancia el Valor en Riesgo para el siguiente período, tanto en períodos normales como en crisis, sobre todo en mercados tan específicos y estándares como los commodities y monedas. Con estos datos y los modelos testeados anteriormente se puede entregar una estimación mucho más certera de lo que ocurrirá en el siguiente período, para el indicador que se desee evaluar y por lo tanto visualizar el riesgo al cual se pueden exponer tanto los fondos de inversión como los costos de empresas productivas, como es el caso de las empresas generadoras de energía en base a Carbón, Petróleo o GAS.

Como conclusión final de las tres metodologías testeadas en este estudio de tesis, podemos apreciar que el CAViaR (*Conditional Autoregressive Value at Risk*) que corresponde a la familia de modelos semiparamétricos, es el mejor para cualquiera sea el período de análisis. En la mayoría de las compañías multinacionales dedicadas al rubro de la energía, existen diversas formas de medir la exposición al riesgo, entre las cuales se encuentra el VaR, sin embargo, difícilmente se realiza con las metodologías semiparamétricas y paramétricas. Así, en este escenario, se debe tener en consideración el CAViaR como metodología imprescindible para calcular la exposición al riesgo y que herramientas de cobertura utilizar, además estos resultados se pueden utilizar, a su vez, como input para decisiones estratégicas de las compañías que, en definitiva, afectan la relación riesgo-retorno y por consiguiente el valor de la acción en el mercado y a su vez impactan sobre indicadores bursátiles agregados.

6 | Referencias Bibliográficas

Acerbi, C. y Tasche, D., 2002. On the Coherence of Expected Shortfall. *Journal of Banking & Finance*, 26(7), pp. 1487-503.

Allen, D. y Singh, A., 2010. CAVIAR and the Australian Stock Markets: An appetizer. *Social Science Research Network*.

Aloui, C. (2008). Value-at-risk analysis for energy commodities: long-range dependencies and fat-tails in return innovations. *Journal of Energy Markets*, 1(1), 31-63.

Aloui, C., & Mabrouk, S. (2010). Value-at-risk estimations of energy commodities via long-memory, asymmetry and fat-tailed GARCH models. *Energy Policy*, 38(5), 2326-2339.

Angelidis, T., Benos, A. y Degiannakis, S., 2014. The Use of GARCH Models in VAR Estimation. *Statistical Methodology*, 1(2), pp. 105-28.

Bali, T., Mo, H. y Tang, Y., 2008. The Role of Autoregressive Conditional Skewness and Kurtosis in the Estimation of Conditional VAR. *Journal of Banking & Finance*, 32(2), pp. 269-82.

Barbeito, J. M., Herrera, C. B., Alonso, S. A., & Chen, D. MODELOS PARAMÉTRICOS Y NO PARAMÉTRICOS, PARA LA PREVISIÓN DE LA VOLATILIDAD. SU APLICACIÓN AL CÁLCULO DEL VALOR EN RIESGO.

Berkowitz, J., Christoffersen, P. y Pelletier, D., 2009. Evaluating Value-at-Risk Models with Desk-Level Data. *Management Science*.

Bollerslev T., 1986. Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31, pp. 307-27.

Bontemps, C. y Meddahi, N., 2006. Testing Normality: A GMM approach. *Journal of Econometrics*, 124, pp.149-86.

Candelon, B.; G. Colletaz; C. Hurlin; y S. Tokpavi, 2011. Backtesting Value-at-Risk: A

GMM duration-based test. *Journal of Finance Econometrics*, 9, pp. 314-43.

Cheng, W. H., & Hung, J. C. (2011). Skewness and leptokurtosis in GARCH-typed VaR estimation of petroleum and metal asset returns. *Journal of Empirical Finance*, 18(1), 160-173.

Christoffersen, P., 1998. Evaluating Interval forecasts. *International Economic Review*, 39, pp. 841-62.

Christoffersen, P. y Pelletier, D., 2004. Backtesting Value-at-Risk: A duration based approach. *Journal of Finance Econometrics*, 2(1), pp. 84-108.

Danielsson, J. y de Vries, C., 2000. Value-at-Risk and Extreme Returns. *Annales d'Economie et de Statistique*, 2000, pp. 239-70.

Duffie, D. y Pan, J., 1997. An Overview of Value at Risk. *Journal of Derivatives*, 4.

Dufour, J., 2006. Monte Carlo test with nuisance parameters: A general approach to finite sample inference and non-standard asymptotics. *Journal of Econometrics*, 127(2), pp. 443-7.

Dusak, K., 1973. Futures Trading and Inverstors Returns: An investigation of commodity markets risk premiums. *Journal of Political Economy*, 81, pp. 1387-406.

Embrechts, P., McNeil, A. y Straumann, S., 2002. Correlation ans Dependence in Risk Management: Properties and Pitfalls. En: Dempster M.A.H. (ed). *Risk Management: Value at Risk and Beyond*. Cambridge: Cambridge University Press.

Engle, R. y Bollerslev, T., 1986. Modelling the Persistence of Conditional Variances. *Econometrics Reviews*, 5, pp. 1-50.

Engle, R. F., & Manganelli, S. (2004). CAViaR: Conditional autoregressive value at risk by regression quantiles. *Journal of Business & Economic Statistics*, 22(4), 367-381.

Engle, R. y Manganelli, s., 2001. Value at Risk Models in Finance. *European Central Bank Working Paper N° 75*, pp. 1-40.

Engle, R. y Ng, V., 1993. Measuring and Testing the Impact of News On Volatility. *Journal of Finance*, 48, pp. 1749-78.

Favre, L. y Galeano, J.A., 2002. Mean-modified Value-at-risk Optimization with Hedge Funds. *The Journal of Alternative Investments*, 5(2), pp. 21-5.

Füss, R., Adams, Z., & Kaiser, D. G. (2010). The predictive power of value-at-risk

models in commodity futures markets. *Journal of Asset Management*, 11(4), 261-285.

Giot, P., & Laurent, S. (2003). Market risk in commodity markets: a VaR approach. *Energy Economics*, 25(5), 435-457.

Greene, W.H., 2002. *Econometrics Analysis*. 5a edición. New Jersey: Pretice Hall.

Hammoudeh, S., Santos, P. A., & Al-Hassan, A. (2013). Downside risk management and VaR-based optimal portfolios for precious metals, oil and stocks. *The North American Journal of Economics and Finance*, 25, 318-334.

Hull, J. y A. White, 1998. Incorporating Volatility Updating into the Historical Simulation Method for Value at Risk. *Journal of Risk*, 1, pp. 5-19.

Hung, J. C., Lee, M. C., & Liu, H. C. (2008). Estimation of value-at-risk for energy commodities via fat-tailed GARCH models. *Energy Economics*, 30(3), 1173-1191.

Jeon, J. y Taylor, J., 2012. Using CAVIAR Models with Implied Volatility for Value at Risk Estimation. *Journal of Forecasting*.

Jorion, P., 1997. Value at Risk: The new benchmark for managing financial risk. Segunda edición. Nueva York: McGraw-Hill.

Koenker, R. y Bassett, G., 1978. Regression Quantiles. *Econometrica*, 46, pp. 33-50.

Lintner, J., 1965. The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets. *Reviews of Economics and Statistics*, 47, pp. 13-37.

Lu, Z., Huang, H., & Gerlach, R. (2010). Estimating Value at Risk: from JP Morgan's standard-EWMA to skewed-EWMA forecasting. *University of Sydney*.

Markowitz, H., 1952. Portfolio Selection. *Journal of Finance*, 7(1), pp. 77-91.

Metropoli, N. y Ulam, S., 1949. The Monte Carlo Method. *Journal of American Statistical Association*, 44, pp. 335-41.

Mossin, j., 1996. Equilibrium in Capital Assets Market. *Econometrica*, 34, pp. 768-83.

Nelson, B.D., 1991. Conditional Heterocedasticity in Assets Returns: A new approach. *Econometrica*, 59(2), 347-70.

Ottenwaelter, M., & Taramasco, O. (2008). Value-at-Risk for commodity portfolios. *INP Grenoble-ENSIMAG*, 1-43.

Ratuszny, E. (2016). Risk Modeling of Commodities using CAViaR Models, the Encompassing Method and the Combined Forecasts. *Dynamic Econometric Models*, 15, 129-156.

Roy, A., 1964. Safety First and the Holding of Assets. *Econometrica*, 20.

Semper, J. D. C., & Clemente, I. M. (1999). Propuesta de la metodología de simulación histórica con predicciones autorregresivas y su aplicación en la estimación del valor en riesgo. *La gestión de la diversidad: XIII Congreso Nacional, IX Congreso Hispano-Francés, Logroño (La Rioja), 16, 17 y 18 de junio, 1999 (pp. 835-844)*. Universidad de La Rioja.

Sharpe, W. 1964- Capital Assets Prices: A theory of market equilibrium under condition of risk. *Journal of Finance*, 19(3), pp. 425-42.

Sosaa, J. A., Cutz, J. L. B., Lara, E. G., Chim, D. K., Peralta, S. M., & Trejo, H. P. Un paseo por el modelo GARCH y sus variantes.

So, M. y Yu, P., 2006 Empirical Analysis of GARCH Models in Value at Risk Estimation. *International Finance Markets, Institutions and Money*, 16, pp. 180-197.

Tobin, J., 1958. Liquidity Preference as Behavior Towards Risk. *The Review of Economic Studies*, 52, pp. 65-86.

A | Anexos

A.1. Test Augmented Dickey Fuller

Augmented Dickey-Fuller Unit Root Test on EUR				
Null Hypothesis: EUR has a unit root				
Exogenous: Constant, Linear Trend				
Lag Length: 0 (Automatic based on SIC, MAXLAG=26)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-50.05225	0.0000
Test critical values:				
1% level			-3.961638	
5% level			-3.411568	
10% level			-3.127650	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(EUR)				
Method: Least Squares				
Date: 05/14/16 Time: 17:45				
Sample(adjusted): 7/19/2006 4/29/2016				
Included observations: 2553 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
EUR(-1)	-0.991483	0.019809	-50.05225	0.0000
C	0.000194	0.000254	0.764341	0.4447
@TREND(7/18/2006)	-1.79E-07	1.72E-07	-1.038904	0.2989
R-squared	0.495572	Mean dependent var		3.64E-06
Adjusted R-squared	0.495176	S.D. dependent var		0.009011
S.E. of regression	0.006402	Akaike info criterion		-7.263160
Sum squared resid	0.104522	Schwarz criterion		-7.256291
Log likelihood	9274.423	F-statistic		1252.615
Durbin-Watson stat	1.998515	Prob(F-statistic)		0.000000

Figura A.1: Test ADF para serie EUR

Augmented Dickey-Fuller Unit Root Test on LIB				
Null Hypothesis: LIB has a unit root				
Exogenous: Constant, Linear Trend				
Lag Length: 0 (Automatic based on SIC, MAXLAG=26)				
			t-Statistic	Prob. *
Augmented Dickey-Fuller test statistic			-48.26120	0.0000
Test critical values:	1% level		-3.961638	
	5% level		-3.411568	
	10% level		-3.127650	
*Mackinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(LIB)				
Method: Least Squares				
Date: 05/14/16 Time: 17:47				
Sample(adjusted): 7/19/2006 4/29/2016				
Included observations: 2553 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
LIB(-1)	-0.954704	0.019782	-48.26120	0.0000
C	-6.31E-05	0.000233	-0.270426	0.7869
@TREND(7/18/2006)	-1.50E-08	1.58E-07	-0.094814	0.9245
R-squared	0.477367	Mean dependent var	-3.06E-07	
Adjusted R-squared	0.476958	S.D. dependent var	0.008146	
S.E. of regression	0.005891	Akaike info criterion	-7.429595	
Sum squared resid	0.088496	Schwarz criterion	-7.422727	
Log likelihood	9486.878	F-statistic	1164.572	
Durbin-Watson stat	1.999001	Prob(F-statistic)	0.000000	

Figura A.2: Test ADF para serie LIB

Augmented Dickey-Fuller Unit Root Test on SIL				
Null Hypothesis: SIL has a unit root				
Exogenous: Constant, Linear Trend				
Lag Length: 0 (Automatic based on SIC, MAXLAG=26)				
			t-Statistic	Prob. *
Augmented Dickey-Fuller test statistic			-55.54711	0.0000
Test critical values:	1% level		-3.961638	
	5% level		-3.411568	
	10% level		-3.127650	
*Mackinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(SIL)				
Method: Least Squares				
Date: 05/14/16 Time: 17:48				
Sample(adjusted): 7/19/2006 4/29/2016				
Included observations: 2553 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
SIL(-1)	-1.094600	0.019706	-55.54711	0.0000
C	0.000983	0.000901	1.090699	0.2755
@TREND(7/18/2006)	-6.10E-07	6.11E-07	-0.997254	0.3187
R-squared	0.547510	Mean dependent var	2.83E-05	
Adjusted R-squared	0.547155	S.D. dependent var	0.033827	
S.E. of regression	0.022763	Akaike info criterion	-4.726174	
Sum squared resid	1.321310	Schwarz criterion	-4.719305	
Log likelihood	6035.961	F-statistic	1542.741	
Durbin-Watson stat	2.000690	Prob(F-statistic)	0.000000	

Figura A.3: Test ADF para serie SIL

Augmented Dickey-Fuller Unit Root Test on GOL				
Null Hypothesis: GOL has a unit root				
Exogenous: Constant, Linear Trend				
Lag Length: 0 (Automatic based on SIC, MAXLAG=26)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-50.15923	0.0000
Test critical values:	1% level		-3.961638	
	5% level		-3.411568	
	10% level		-3.127650	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(GOL)				
Method: Least Squares				
Date: 05/14/16 Time: 17:47				
Sample(adjusted): 7/19/2006 4/29/2016				
Included observations: 2553 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
GOL(-1)	-0.993432	0.019806	-50.15923	0.0000
C	0.000798	0.000481	1.661274	0.0968
@TREND(7/18/2006)	-4.06E-07	3.26E-07	-1.246300	0.2128
R-squared	0.496639	Mean dependent var		1.57E-05
Adjusted R-squared	0.496244	S.D. dependent var		0.017091
S.E. of regression	0.012131	Akaike info criterion		-5.984997
Sum squared resid	0.375236	Schwarz criterion		-5.978128
Log likelihood	7642.848	F-statistic		1257.974
Durbin-Watson stat	1.996092	Prob(F-statistic)		0.000000

Figura A.4: Test ADF para serie GOL

Augmented Dickey-Fuller Unit Root Test on COP				
Null Hypothesis: COP has a unit root				
Exogenous: Constant, Linear Trend				
Lag Length: 0 (Automatic based on SIC, MAXLAG=26)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-54.45962	0.0000
Test critical values:	1% level		-3.961638	
	5% level		-3.411568	
	10% level		-3.127650	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(COP)				
Method: Least Squares				
Date: 05/14/16 Time: 17:44				
Sample(adjusted): 7/19/2006 4/29/2016				
Included observations: 2553 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
COP(-1)	-1.075527	0.019749	-54.45962	0.0000
C	-2.00E-06	0.000734	-0.002729	0.9978
@TREND(7/18/2006)	-1.47E-07	4.98E-07	-0.295297	0.7678
R-squared	0.537696	Mean dependent var		3.25E-06
Adjusted R-squared	0.537334	S.D. dependent var		0.027269
S.E. of regression	0.018548	Akaike info criterion		-5.135693
Sum squared resid	0.877309	Schwarz criterion		-5.128825
Log likelihood	6558.713	F-statistic		1482.926
Durbin-Watson stat	1.999487	Prob(F-statistic)		0.000000

Figura A.5: Test ADF para serie COP

Augmented Dickey-Fuller Unit Root Test on BRE				
Null Hypothesis: BRE has a unit root				
Exogenous: Constant, Linear Trend				
Lag Length: 0 (Automatic based on SIC, MAXLAG=26)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-54.08923	0.0000
Test critical values:	1% level		-3.961638	
	5% level		-3.411568	
	10% level		-3.127650	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(BRE)				
Method: Least Squares				
Date: 05/14/16 Time: 17:40				
Sample(adjusted): 7/19/2006 4/29/2016				
Included observations: 2553 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
BRE(-1)	-1.068416	0.019753	-54.08923	0.0000
C	0.000592	0.000863	0.686921	0.4922
@TREND(7/18/2006)	-6.07E-07	5.85E-07	-1.037439	0.2996
R-squared	0.534301	Mean dependent var		8.05E-06
Adjusted R-squared	0.533936	S.D. dependent var		0.031907
S.E. of regression	0.021782	Akaike info criterion		-4.814253
Sum squared resid	1.209908	Schwarz criterion		-4.807385
Log likelihood	6148.394	F-statistic		1462.823
Durbin-Watson stat	2.001354	Prob(F-statistic)		0.000000

Figura A.6: Test ADF para serie BRE

Augmented Dickey-Fuller Unit Root Test on WTI				
Null Hypothesis: WTI has a unit root				
Exogenous: Constant, Linear Trend				
Lag Length: 0 (Automatic based on SIC, MAXLAG=26)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-53.14102	0.0000
Test critical values:	1% level		-3.961638	
	5% level		-3.411568	
	10% level		-3.127650	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(WTI)				
Method: Least Squares				
Date: 05/14/16 Time: 17:49				
Sample(adjusted): 7/19/2006 4/29/2016				
Included observations: 2553 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
WTI(-1)	-1.050790	0.019774	-53.14102	0.0000
C	0.000481	0.000965	0.498099	0.6185
@TREND(7/18/2006)	-5.28E-07	6.55E-07	-0.806947	0.4198
R-squared	0.525490	Mean dependent var		8.75E-06
Adjusted R-squared	0.525118	S.D. dependent var		0.035366
S.E. of regression	0.024372	Akaike info criterion		-4.589626
Sum squared resid	1.514631	Schwarz criterion		-4.582757
Log likelihood	5861.657	F-statistic		1411.985
Durbin-Watson stat	2.005324	Prob(F-statistic)		0.000000

Figura A.7: Test ADF para serie WTI

Augmented Dickey-Fuller Unit Root Test on GAS				
Null Hypothesis: GAS has a unit root				
Exogenous: Constant, Linear Trend				
Lag Length: 0 (Automatic based on SIC, MAXLAG=26)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-54.73156	0.0000
Test critical values:	1% level		-3.961638	
	5% level		-3.411568	
	10% level		-3.127650	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(GAS)				
Method: Least Squares				
Date: 05/14/16 Time: 17:46				
Sample(adjusted): 7/19/2006 4/29/2016				
Included observations: 2553 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
GAS(-1)	-1.080057	0.019734	-54.73156	0.0000
C	0.000154	0.001239	0.124040	0.9013
@TREND(7/18/2006)	-4.43E-07	8.40E-07	-0.527253	0.5981
R-squared	0.540171	Mean dependent var		2.08E-05
Adjusted R-squared	0.539811	S.D. dependent var		0.046134
S.E. of regression	0.031296	Akaike info criterion		-4.089456
Sum squared resid	2.497628	Schwarz criterion		-4.082587
Log likelihood	5223.190	F-statistic		1497.772
Durbin-Watson stat	1.991089	Prob(F-statistic)		0.000000

Figura A.8: Test ADF para serie GAS

Augmented Dickey-Fuller Unit Root Test on CSA				
Null Hypothesis: CSA has a unit root				
Exogenous: Constant, Linear Trend				
Lag Length: 0 (Automatic based on SIC, MAXLAG=26)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-50.23821	0.0000
Test critical values:	1% level		-3.961638	
	5% level		-3.411568	
	10% level		-3.127650	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(CSA)				
Method: Least Squares				
Date: 05/14/16 Time: 17:44				
Sample(adjusted): 7/19/2006 4/29/2016				
Included observations: 2553 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
CSA(-1)	-0.994879	0.019803	-50.23821	0.0000
C	0.000987	0.000625	1.580359	0.1141
@TREND(7/18/2006)	-7.58E-07	4.24E-07	-1.788142	0.0739
R-squared	0.497426	Mean dependent var		6.67E-07
Adjusted R-squared	0.497032	S.D. dependent var		0.022238
S.E. of regression	0.015771	Akaike info criterion		-5.460063
Sum squared resid	0.634279	Schwarz criterion		-5.453195
Log likelihood	6972.770	F-statistic		1261.939
Durbin-Watson stat	1.998434	Prob(F-statistic)		0.000000

Figura A.9: Test ADF para serie CSA

Augmented Dickey-Fuller Unit Root Test on CEU				
Null Hypothesis: CEU has a unit root				
Exogenous: Constant, Linear Trend				
Lag Length: 0 (Automatic based on SIC, MAXLAG=26)				
		t-Statistic	Prob.	
Augmented Dickey-Fuller test statistic		-48.81137	0.0000	
Test critical values:	1% level	-3.961638		
	5% level	-3.411568		
	10% level	-3.127650		
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(CEU)				
Method: Least Squares				
Date: 05/14/16 Time: 17:39				
Sample(adjusted): 7/19/2006 4/29/2016				
Included observations: 2553 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
CEU(-1)	-0.966046	0.019791	-48.81137	0.0000
C	0.000884	0.000611	1.445432	0.1485
@TREND(7/18/2006)	-7.91E-07	4.15E-07	-1.907259	0.0566
R-squared	0.483026	Mean dependent var	-1.53E-06	
Adjusted R-squared	0.482621	S.D. dependent var	0.021455	
S.E. of regression	0.015433	Akaike info criterion	-5.503477	
Sum squared resid	0.607332	Schwarz criterion	-5.496608	
Log likelihood	7028.188	F-statistic	1191.275	
Durbin-Watson stat	1.997973	Prob(F-statistic)	0.000000	

Figura A.10: Test ADF para serie CEU

A.2. Test Levene

Test for Equality of Variances of EUR				
Categorized by values of EUR				
Date: 05/15/16 Time: 16:51				
Sample: 7/18/2006 4/29/2016				
Included observations: 2554				
Method	df	Value	Probability	
Bartlett	3	14.06583	0.0028	
Levene	(3, 2550)	4.039605	0.0071	
Brown-Forsythe	(3, 2550)	3.790566	0.0100	
Category Statistics				
EUR	Count	Std. Dev.	Mean Abs. Mean Diff.	Mean Abs. Median Diff.
[-0.04, -0.02)	12	0.002461	0.001715	0.001326
[-0.02, 0)	1241	0.004024	0.003147	0.003033
[0, 0.02)	1285	0.003693	0.002890	0.002759
[0.02, 0.04)	16	0.004783	0.003715	0.003690
All	2554	0.006400	0.003015	0.002891
Bartlett weighted standard deviation: 0.003860				

Figura A.11: Test Levene para serie EUR

Test for Equality of Variances of LIB
 Categorized by values of LIB
 Date: 05/15/16 Time: 16:53
 Sample: 7/18/2006 4/29/2016
 Included observations: 2554

Method	df	Value	Probability
Bartlett	3	6.991715	0.0722
Levene	(3, 2550)	2.664042	0.0464
Brown-Forsythe	(3, 2550)	1.487849	0.2158

Category Statistics

LIB	Count	Std. Dev.	Mean Abs. Mean Diff.	Mean Abs. Median Diff.
[-0.04, -0.02)	16	0.005357	0.004311	0.003976
[-0.02, 0)	1254	0.003535	0.002743	0.002640
[0, 0.02)	1278	0.003520	0.002751	0.002639
[0.02, 0.04)	6	0.004044	0.002996	0.002996
All	2554	0.005894	0.002758	0.002649

Bartlett weighted standard deviation: 0.003542

Figura A.12: Test Levene para serie LIB

Test for Equality of Variances of SIL
 Categorized by values of SIL
 Date: 05/15/16 Time: 16:54
 Sample: 7/18/2006 4/29/2016
 Included observations: 2554

Method	df	Value	Probability
Bartlett	3	37.36195	0.0000
Levene	(3, 2550)	18.27267	0.0000
Brown-Forsythe	(3, 2550)	10.53441	0.0000

Category Statistics

SIL	Count	Std. Dev.	Mean Abs. Mean Diff.	Mean Abs. Median Diff.
[-0.2, -0.1)	9	0.028647	0.023110	0.022607
[-0.1, 0)	1185	0.014318	0.010722	0.010213
[0, 0.1)	1355	0.013509	0.010160	0.009804
[0.1, 0.2)	5	0.040069	0.034967	0.029630
All	2554	0.022872	0.010515	0.010077

Bartlett weighted standard deviation: 0.014042

Figura A.13: Test Levene para serie SIL

Test for Equality of Variances of GOL
 Categorized by values of GOL
 Date: 05/15/16 Time: 16:52
 Sample: 7/18/2006 4/29/2016
 Included observations: 2554

Method	df	Value	Probability
Bartlett	4	13.68420	0.0084
Levene	(4, 2549)	2.930401	0.0197
Brown-Forsythe	(4, 2549)	0.831581	0.5049

Category Statistics

GOL	Count	Std. Dev.	Mean Abs. Mean Diff.	Mean Abs. Median Diff.
[-0.1, -0.05)	8	0.012887	0.009729	0.007705
[-0.05, 0)	1216	0.007965	0.006081	0.005688
[0, 0.05)	1327	0.007310	0.005634	0.005443
[0.05, 0.1)	2	0.008956	0.006333	0.006333
[0.1, 0.15)	1	NA	0.000000	0.000000
All	2554	0.012133	0.005858	0.005565

Bartlett weighted standard deviation: 0.007650

Figura A.14: Test Levene para serie GOL

Test for Equality of Variances of COP
 Categorized by values of COP
 Date: 05/15/16 Time: 16:49
 Sample: 7/18/2006 4/29/2016
 Included observations: 2554

Method	df	Value	Probability
Bartlett	5	1.362862	0.9283
Levene	(5, 2548)	1.741825	0.1217
Brown-Forsythe	(5, 2548)	1.203835	0.3047

Category Statistics

COP	Count	Std. Dev.	Mean Abs. Mean Diff.	Mean Abs. Median Diff.
[-0.15, -0.1)	1	NA	0.000000	0.000000
[-0.1, -0.05)	29	0.011686	0.009885	0.009702
[-0.05, 0)	1209	0.010553	0.008334	0.008060
[0, 0.05)	1288	0.010532	0.008377	0.008101
[0.05, 0.1)	26	0.009297	0.005943	0.005918
[0.1, 0.15)	1	NA	0.000000	0.000000
All	2554	0.018592	0.008342	0.008071

Bartlett weighted standard deviation: 0.010544

Figura A.15: Test Levene para serie COP

Test for Equality of Variances of BRE
 Categorized by values of BRE
 Date: 05/15/16 Time: 16:48
 Sample: 7/18/2006 4/29/2016
 Included observations: 2554

Method	df	Value	Probability
Bartlett	5	14.50598	0.0127
Levene	(5, 2548)	3.306208	0.0056
Brown-Forsythe	(5, 2548)	2.063741	0.0671

Category Statistics

BRE	Count	Std. Dev.	Mean Abs. Mean Diff.	Mean Abs. Median Diff.
[-0.15, -0.1)	2	0.000379	0.000268	0.000268
[-0.1, -0.05)	52	0.013117	0.010489	0.010024
[-0.05, 0)	1218	0.011053	0.008921	0.008593
[0, 0.05)	1238	0.011164	0.008929	0.008529
[0.05, 0.1)	41	0.014648	0.012310	0.011672
[0.1, 0.15)	3	0.011724	0.008602	0.007635
All	2554	0.021829	0.009004	0.008633

Bartlett weighted standard deviation: 0.011215

Figura A.16: Test Levene para serie BRE

Test for Equality of Variances of WTI
 Categorized by values of WTI
 Date: 05/15/16 Time: 16:55
 Sample: 7/18/2006 4/29/2016
 Included observations: 2554

Method	df	Value	Probability
Bartlett	3	2.867731	0.4125
Levene	(3, 2550)	1.000773	0.3914
Brown-Forsythe	(3, 2550)	1.023094	0.3813

Category Statistics

WTI	Count	Std. Dev.	Mean Abs. Mean Diff.	Mean Abs. Median Diff.
[-0.2, -0.1)	7	0.011399	0.009157	0.007569
[-0.1, 0)	1219	0.016007	0.011812	0.011278
[0, 0.1)	1320	0.015592	0.011349	0.010778
[0.1, 0.2)	8	0.020312	0.016176	0.016176
All	2554	0.024396	0.011579	0.011025

Bartlett weighted standard deviation: 0.015798

Figura A.17: Test Levene para serie WTI

Test for Equality of Variances of GAS
 Categorized by values of GAS
 Date: 05/15/16 Time: 16:51
 Sample: 7/18/2006 4/29/2016
 Included observations: 2554

Method	df	Value	Probability
Bartlett	4	1.263533	0.8675
Levene	(4, 2549)	0.330372	0.8577
Brown-Forsythe	(4, 2549)	0.325658	0.8609

Category Statistics

GAS	Count	Std. Dev.	Mean Abs. Mean Diff.	Mean Abs. Median Diff.
[-0.2, -0.1)	6	0.018418	0.013501	0.011487
[-0.1, 0)	1245	0.018054	0.014013	0.013622
[0, 0.1)	1283	0.018496	0.014195	0.013661
[0.1, 0.2)	18	0.020440	0.016517	0.016517
[0.2, 0.3)	2	0.012811	0.009059	0.009059
All	2554	0.031390	0.014117	0.013653

Bartlett weighted standard deviation: 0.018294

Figura A.18: Test Levene para serie GAS

Test for Equality of Variances of CSA
 Categorized by values of CSA
 Date: 05/15/16 Time: 16:50
 Sample: 7/18/2006 4/29/2016
 Included observations: 2554

Method	df	Value	Probability
Bartlett	5	8.224477	0.1443
Levene	(5, 2548)	0.497124	0.7786
Brown-Forsythe	(5, 2548)	0.310100	0.9071

Category Statistics

CSA	Count	Std. Dev.	Mean Abs. Mean Diff.	Mean Abs. Median Diff.
[-0.3, -0.2)	1	NA	0.000000	0.000000
[-0.2, -0.1)	2	0.007061	0.004993	0.004993
[-0.1, 0)	1135	0.011468	0.006990	0.006231
[0, 0.1)	1411	0.010560	0.006620	0.005889
[0.1, 0.2)	4	0.009967	0.006566	0.006133
[0.2, 0.3)	1	NA	0.000000	0.000000
All	2554	0.015773	0.006778	0.006036

Bartlett weighted standard deviation: 0.010972

Figura A.19: Test Levene para serie CSA

Test for Equality of Variances of CEU

Categorized by values of CEU

Date: 05/15/16 Time: 16:47

Sample: 7/18/2006 4/29/2016

Included observations: 2554

Method	df	Value	Probability
Bartlett	4	47.69603	0.0000
Levene	(4, 2549)	6.628918	0.0000
Brown-Forsythe	(4, 2549)	3.958884	0.0033

Category Statistics

CEU	Count	Std. Dev.	Mean Abs. Mean Diff.	Mean Abs. Median Diff.
[-0.3, -0.2)	1	NA	0.000000	0.000000
[-0.2, -0.1)	5	0.024811	0.017478	0.013726
[-0.1, 0)	1113	0.011393	0.006963	0.006069
[0, 0.1)	1431	0.009799	0.006179	0.005472
[0.1, 0.2)	4	0.026297	0.020582	0.020582
All	2554	0.015445	0.006563	0.005770

Bartlett weighted standard deviation: 0.010596

Figura A.20: Test Levene para serie CEU

A.3. Resultados Data Total

A.3.1. EUR

Resultados HS EUR

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi,(2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 125
Empirical frequency of violations = 0.0543
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
***  Conditional and Unconditional (p=1) Coverage (UC) Tests  **
*****

p = 1   J_UC statistic = 1.0201      J_UC pvalue (corrected) = 0.2936
p = 2   J_CC statistic = 93.6050     J_CC pvalue (corrected) = 0.0001
p = 3   J_CC statistic = 96.6876     J_CC pvalue (corrected) = 0.0005
p = 4   J_CC statistic = 108.7434    J_CC pvalue (corrected) = 0.0008
p = 5   J_CC statistic = 112.1666    J_CC pvalue (corrected) = 0.0009
p = 6   J_CC statistic = 133.7902    J_CC pvalue (corrected) = 0.0009

*****
***  Independence (IND) Tests  **
*****

p = 1   J_IND statistic = 0.0093     J_IND pvalue (corrected) = 0.7379
p = 2   J_IND statistic = 128.0049   J_IND pvalue (corrected) = 0.0001
p = 3   J_IND statistic = 156.2605   J_IND pvalue (corrected) = 0.0001
p = 4   J_IND statistic = 168.7486   J_IND pvalue (corrected) = 0.0003
p = 5   J_IND statistic = 191.4412   J_IND pvalue (corrected) = 0.0003
p = 6   J_IND statistic = 224.0273   J_IND pvalue (corrected) = 0.0003

```

Resultados GARCH EUR

```
=====
== Backtesting Value-at-Risk: A GMM Duration Based Test ==
== Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====
```

Coverate Rate of Value-at-Risk = 0.05

Number of violations = 237

Empirical frequency of violations = 0.1030

Maximal number of polynomials = 6

Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*** Conditional and Unconditional (p=1) Coverage (UC) Tests **

p = 1	J_UC statistic = 66.9673	J_UC pvalue (corrected) = 0.0001
p = 2	J_CC statistic = 91.3877	J_CC pvalue (corrected) = 0.0001
p = 3	J_CC statistic = 101.6146	J_CC pvalue (corrected) = 0.0011
p = 4	J_CC statistic = 105.9741	J_CC pvalue (corrected) = 0.0013
p = 5	J_CC statistic = 107.8196	J_CC pvalue (corrected) = 0.0015
p = 6	J_CC statistic = 108.6781	J_CC pvalue (corrected) = 0.0016

*** Independence (IND) Tests **

p = 1	J_IND statistic = 0.0057	J_IND pvalue (corrected) = 0.9093
p = 2	J_IND statistic = 7.3132	J_IND pvalue (corrected) = 0.0084
p = 3	J_IND statistic = 7.6052	J_IND pvalue (corrected) = 0.0210
p = 4	J_IND statistic = 7.7590	J_IND pvalue (corrected) = 0.0300
p = 5	J_IND statistic = 9.9638	J_IND pvalue (corrected) = 0.0223
p = 6	J_IND statistic = 13.2902	J_IND pvalue (corrected) = 0.0171

Resultados CAVIAR EUR

```
=====
== Backtesting Value-at-Risk: A GMM Duration Based Test ==
== Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====
```

Coverate Rate of Value-at-Risk = 0.05

Number of violations = 117

Empirical frequency of violations = 0.0509

Maximal number of polynomials = 6

Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*** Conditional and Unconditional (p=1) Coverage (UC) Tests **

```
p = 1   J_UC statistic = 0.0830   J_UC pvalue (corrected) = 0.7425
p = 2   J_CC statistic = 1.0715   J_CC pvalue (corrected) = 0.5546
p = 3   J_CC statistic = 1.3932   J_CC pvalue (corrected) = 0.5831
p = 4   J_CC statistic = 1.4952   J_CC pvalue (corrected) = 0.6638
p = 5   J_CC statistic = 1.5937   J_CC pvalue (corrected) = 0.7038
p = 6   J_CC statistic = 1.6819   J_CC pvalue (corrected) = 0.7469
```

*** Independence (IND) Tests **

```
p = 1   J_IND statistic = 0.0099   J_IND pvalue (corrected) = 0.5115
p = 2   J_IND statistic = 1.0853   J_IND pvalue (corrected) = 0.2643
p = 3   J_IND statistic = 1.3800   J_IND pvalue (corrected) = 0.3328
p = 4   J_IND statistic = 1.4712   J_IND pvalue (corrected) = 0.4500
p = 5   J_IND statistic = 1.5699   J_IND pvalue (corrected) = 0.5150
p = 6   J_IND statistic = 1.6569   J_IND pvalue (corrected) = 0.5709
```

A.3.2. LIB

Resultados HS LIB

```
=====
== Backtesting Value-at-Risk: A GMM Duration Based Test ==
== Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====
```

Coverate Rate of Value-at-Risk = 0.05

Number of violations = 125

Empirical frequency of violations = 0.0543

Maximal number of polynomials = 6

Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

```
*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests ***
*****
```

p = 1	J_UC statistic = 1.0201	J_UC pvalue (corrected) = 0.2954
p = 2	J_CC statistic = 39.6346	J_CC pvalue (corrected) = 0.0004
p = 3	J_CC statistic = 40.1103	J_CC pvalue (corrected) = 0.0038
p = 4	J_CC statistic = 40.9689	J_CC pvalue (corrected) = 0.0038
p = 5	J_CC statistic = 41.3809	J_CC pvalue (corrected) = 0.0057
p = 6	J_CC statistic = 43.4079	J_CC pvalue (corrected) = 0.0055

```
*****
*** Independence (IND) Tests ***
*****
```

p = 1	J_IND statistic = 0.0093	J_IND pvalue (corrected) = 0.7429
p = 2	J_IND statistic = 52.8401	J_IND pvalue (corrected) = 0.0002
p = 3	J_IND statistic = 53.9815	J_IND pvalue (corrected) = 0.0012
p = 4	J_IND statistic = 55.6018	J_IND pvalue (corrected) = 0.0015
p = 5	J_IND statistic = 58.1225	J_IND pvalue (corrected) = 0.0020
p = 6	J_IND statistic = 60.9775	J_IND pvalue (corrected) = 0.0021

Resultados GARCH LIB

```
=====
== Backtesting Value-at-Risk: A GMM Duration Based Test ==
== Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====
```

Coverate Rate of Value-at-Risk = 0.05

Number of violations = 203

Empirical frequency of violations = 0.0883

Maximal number of polynomials = 6

Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

```
*****
```

```
*** Conditional and Unconditional (p=1) Coverage (UC) Tests ***
```

```
*****
```

```
p = 1   J_UC statistic = 40.9180   J_UC pvalue (corrected) = 0.0001
p = 2   J_CC statistic = 51.0874   J_CC pvalue (corrected) = 0.0002
p = 3   J_CC statistic = 54.6786   J_CC pvalue (corrected) = 0.0025
p = 4   J_CC statistic = 56.3490   J_CC pvalue (corrected) = 0.0025
p = 5   J_CC statistic = 57.1752   J_CC pvalue (corrected) = 0.0032
p = 6   J_CC statistic = 57.5371   J_CC pvalue (corrected) = 0.0036
```

```
*****
```

```
*** Independence (IND) Tests ***
```

```
*****
```

```
p = 1   J_IND statistic = 0.0064   J_IND pvalue (corrected) = 0.9040
p = 2   J_IND statistic = 1.1147   J_IND pvalue (corrected) = 0.2509
p = 3   J_IND statistic = 2.2180   J_IND pvalue (corrected) = 0.1928
p = 4   J_IND statistic = 2.2389   J_IND pvalue (corrected) = 0.2735
p = 5   J_IND statistic = 2.3720   J_IND pvalue (corrected) = 0.3353
p = 6   J_IND statistic = 2.4722   J_IND pvalue (corrected) = 0.3885
```

Resultados CAVIAR LIB

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 115
Empirical frequency of violations = 0.0500
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1  J_UC statistic = 0.0100  J_UC pvalue (corrected) = 0.9170
p = 2  J_CC statistic = 2.0552  J_CC pvalue (corrected) = 0.3274
p = 3  J_CC statistic = 2.3760  J_CC pvalue (corrected) = 0.3742
p = 4  J_CC statistic = 2.4298  J_CC pvalue (corrected) = 0.4515
p = 5  J_CC statistic = 2.6076  J_CC pvalue (corrected) = 0.4891
p = 6  J_CC statistic = 2.6332  J_CC pvalue (corrected) = 0.5447

*****
*** Independence (IND) Tests **
*****

p = 1  J_IND statistic = 0.0100  J_IND pvalue (corrected) = 0.4648
p = 2  J_IND statistic = 2.0552  J_IND pvalue (corrected) = 0.1148
p = 3  J_IND statistic = 2.3760  J_IND pvalue (corrected) = 0.1739
p = 4  J_IND statistic = 2.4298  J_IND pvalue (corrected) = 0.2491
p = 5  J_IND statistic = 2.6076  J_IND pvalue (corrected) = 0.3005
p = 6  J_IND statistic = 2.6332  J_IND pvalue (corrected) = 0.3585

```

A.3.3. SIL

Resultados HS SIL

```
=====
== Backtesting Value-at-Risk: A GMM Duration Based Test ==
== Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====
```

Coverate Rate of Value-at-Risk = 0.05

Number of violations = 109

Empirical frequency of violations = 0.0474

Maximal number of polynomials = 6

Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

```
*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****
```

p = 1	J_UC statistic = 0.2345	J_UC pvalue (corrected) = 0.6174
p = 2	J_CC statistic = 66.4256	J_CC pvalue (corrected) = 0.0001
p = 3	J_CC statistic = 148.4120	J_CC pvalue (corrected) = 0.0007
p = 4	J_CC statistic = 173.7266	J_CC pvalue (corrected) = 0.0010
p = 5	J_CC statistic = 232.2001	J_CC pvalue (corrected) = 0.0009
p = 6	J_CC statistic = 237.5513	J_CC pvalue (corrected) = 0.0010

```
*****
*** Independence (IND) Tests **
*****
```

p = 1	J_IND statistic = 0.0105	J_IND pvalue (corrected) = 0.2676
p = 2	J_IND statistic = 52.8625	J_IND pvalue (corrected) = 0.0001
p = 3	J_IND statistic = 95.2661	J_IND pvalue (corrected) = 0.0004
p = 4	J_IND statistic = 101.6238	J_IND pvalue (corrected) = 0.0007
p = 5	J_IND statistic = 146.2555	J_IND pvalue (corrected) = 0.0003
p = 6	J_IND statistic = 146.3783	J_IND pvalue (corrected) = 0.0007

Resultados GARCH SIL

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi,(2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 101
Empirical frequency of violations = 0.0439
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 1.7307      J_UC pvalue (corrected) = 0.2037
p = 2   J_CC statistic = 18.7593     J_CC pvalue (corrected) = 0.0043
p = 3   J_CC statistic = 67.9499     J_CC pvalue (corrected) = 0.0025
p = 4   J_CC statistic = 75.7304     J_CC pvalue (corrected) = 0.0027
p = 5   J_CC statistic = 101.6045    J_CC pvalue (corrected) = 0.0024
p = 6   J_CC statistic = 102.2074    J_CC pvalue (corrected) = 0.0026

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0112     J_IND pvalue (corrected) = 0.0806
p = 2   J_IND statistic = 9.2072     J_IND pvalue (corrected) = 0.0062
p = 3   J_IND statistic = 21.8719    J_IND pvalue (corrected) = 0.0046
p = 4   J_IND statistic = 22.0462    J_IND pvalue (corrected) = 0.0052
p = 5   J_IND statistic = 30.8454    J_IND pvalue (corrected) = 0.0049
p = 6   J_IND statistic = 34.1400    J_IND pvalue (corrected) = 0.0045

>>

```

Resultados CAVIAR SIL

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 106
Empirical frequency of violations = 0.0461
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 0.6218   J_UC pvalue (corrected) = 0.4199
p = 2   J_CC statistic = 6.9767   J_CC pvalue (corrected) = 0.0365
p = 3   J_CC statistic = 42.9517   J_CC pvalue (corrected) = 0.0041
p = 4   J_CC statistic = 44.2907   J_CC pvalue (corrected) = 0.0044
p = 5   J_CC statistic = 54.8846   J_CC pvalue (corrected) = 0.0044
p = 6   J_CC statistic = 56.2286   J_CC pvalue (corrected) = 0.0045

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0107   J_IND pvalue (corrected) = 0.1897
p = 2   J_IND statistic = 4.3502   J_IND pvalue (corrected) = 0.0289
p = 3   J_IND statistic = 21.6898   J_IND pvalue (corrected) = 0.0053
p = 4   J_IND statistic = 22.0340   J_IND pvalue (corrected) = 0.0056
p = 5   J_IND statistic = 26.8146   J_IND pvalue (corrected) = 0.0057
p = 6   J_IND statistic = 26.9451   J_IND pvalue (corrected) = 0.0060

```

A.3.4. GOL

Resultados HS GOL

```
=====
== Backtesting Value-at-Risk: A GMM Duration Based Test ==
== Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====
```

Coverate Rate of Value-at-Risk = 0.05

Number of violations = 119

Empirical frequency of violations = 0.0517

Maximal number of polynomials = 6

Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

```
*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****
```

p = 1	J_UC statistic = 0.2237	J_UC pvalue (corrected) = 0.6650
p = 2	J_CC statistic = 44.8019	J_CC pvalue (corrected) = 0.0006
p = 3	J_CC statistic = 109.6003	J_CC pvalue (corrected) = 0.0017
p = 4	J_CC statistic = 192.7083	J_CC pvalue (corrected) = 0.0013
p = 5	J_CC statistic = 198.7654	J_CC pvalue (corrected) = 0.0013
p = 6	J_CC statistic = 254.4259	J_CC pvalue (corrected) = 0.0014

```
*****
*** Independence (IND) Tests **
*****
```

p = 1	J_IND statistic = 0.0097	J_IND pvalue (corrected) = 0.6161
p = 2	J_IND statistic = 51.0082	J_IND pvalue (corrected) = 0.0003
p = 3	J_IND statistic = 145.2912	J_IND pvalue (corrected) = 0.0006
p = 4	J_IND statistic = 285.0847	J_IND pvalue (corrected) = 0.0006
p = 5	J_IND statistic = 285.9729	J_IND pvalue (corrected) = 0.0006
p = 6	J_IND statistic = 378.6997	J_IND pvalue (corrected) = 0.0006

Resultados GARCH GOL

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi,(2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 137
Empirical frequency of violations = 0.0596
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 4.0527   J_UC pvalue (corrected) = 0.0412
p = 2   J_CC statistic = 6.0167   J_CC pvalue (corrected) = 0.0498
p = 3   J_CC statistic = 6.0354   J_CC pvalue (corrected) = 0.0815
p = 4   J_CC statistic = 6.1475   J_CC pvalue (corrected) = 0.1076
p = 5   J_CC statistic = 6.2225   J_CC pvalue (corrected) = 0.1329
p = 6   J_CC statistic = 7.4113   J_CC pvalue (corrected) = 0.1143

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0087   J_IND pvalue (corrected) = 0.8855
p = 2   J_IND statistic = 2.3048   J_IND pvalue (corrected) = 0.0922
p = 3   J_IND statistic = 2.8871   J_IND pvalue (corrected) = 0.1295
p = 4   J_IND statistic = 3.0991   J_IND pvalue (corrected) = 0.1758
p = 5   J_IND statistic = 4.8015   J_IND pvalue (corrected) = 0.1156
p = 6   J_IND statistic = 8.8777   J_IND pvalue (corrected) = 0.0406

```

Resultados CAVIAR GOL

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 104
Empirical frequency of violations = 0.0452
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 0.9925   J_UC pvalue (corrected) = 0.3213
p = 2   J_CC statistic = 1.0068   J_CC pvalue (corrected) = 0.5832
p = 3   J_CC statistic = 1.0922   J_CC pvalue (corrected) = 0.6726
p = 4   J_CC statistic = 1.1626   J_CC pvalue (corrected) = 0.7574
p = 5   J_CC statistic = 1.4380   J_CC pvalue (corrected) = 0.7466
p = 6   J_CC statistic = 1.4397   J_CC pvalue (corrected) = 0.7963

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0109   J_IND pvalue (corrected) = 0.1317
p = 2   J_IND statistic = 0.0416   J_IND pvalue (corrected) = 0.8520
p = 3   J_IND statistic = 0.0703   J_IND pvalue (corrected) = 0.9610
p = 4   J_IND statistic = 0.0803   J_IND pvalue (corrected) = 0.9884
p = 5   J_IND statistic = 0.2248   J_IND pvalue (corrected) = 0.9658
p = 6   J_IND statistic = 0.2767   J_IND pvalue (corrected) = 0.9710

```

A.3.5. COP

Resultados HS COP

```
=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi,(2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 101
Empirical frequency of violations = 0.0439
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 1.7307      J_UC pvalue (corrected) = 0.1962
p = 2   J_CC statistic = 229.6151    J_CC pvalue (corrected) = 0.0001
p = 3   J_CC statistic = 968.6415    J_CC pvalue (corrected) = 0.0001
p = 4   J_CC statistic = 2315.0883   J_CC pvalue (corrected) = 0.0001
p = 5   J_CC statistic = 2337.6988   J_CC pvalue (corrected) = 0.0001
p = 6   J_CC statistic = 3034.1179   J_CC pvalue (corrected) = 0.0001

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0112     J_IND pvalue (corrected) = 0.0866
p = 2   J_IND statistic = 130.8778   J_IND pvalue (corrected) = 0.0001
p = 3   J_IND statistic = 325.5699   J_IND pvalue (corrected) = 0.0001
p = 4   J_IND statistic = 508.9066   J_IND pvalue (corrected) = 0.0002
p = 5   J_IND statistic = 578.9220   J_IND pvalue (corrected) = 0.0001
p = 6   J_IND statistic = 666.5034   J_IND pvalue (corrected) = 0.0002
```

Resultados GARCH COP

```
=====
== Backtesting Value-at-Risk: A GMM Duration Based Test ==
== Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====
```

```
Coverate Rate of Value-at-Risk = 0.05
Number of violations = 131
Empirical frequency of violations = 0.0570
Maximal number of polynomials = 6
Sample size = 2300
```

```
Number of simulations (for Dufour's correction)= 9999
```

```
*****
```

```
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
```

```
*****
```

```
p = 1   J_UC statistic = 2.3182      J_UC pvalue (corrected) = 0.1188
p = 2   J_CC statistic = 132.1691    J_CC pvalue (corrected) = 0.0001
p = 3   J_CC statistic = 183.1623    J_CC pvalue (corrected) = 0.0004
p = 4   J_CC statistic = 234.6040    J_CC pvalue (corrected) = 0.0008
p = 5   J_CC statistic = 309.9544    J_CC pvalue (corrected) = 0.0005
p = 6   J_CC statistic = 311.2008    J_CC pvalue (corrected) = 0.0008
```

```
*****
```

```
*** Independence (IND) Tests **
```

```
*****
```

```
p = 1   J_IND statistic = 0.0090      J_IND pvalue (corrected) = 0.8541
p = 2   J_IND statistic = 214.1260    J_IND pvalue (corrected) = 0.0001
p = 3   J_IND statistic = 503.1733    J_IND pvalue (corrected) = 0.0002
p = 4   J_IND statistic = 910.8376    J_IND pvalue (corrected) = 0.0002
p = 5   J_IND statistic = 941.6790    J_IND pvalue (corrected) = 0.0002
p = 6   J_IND statistic = 1099.8573   J_IND pvalue (corrected) = 0.0002
```

Resultados CAVIAR COP

```
=====
== Backtesting Value-at-Risk: A GMM Duration Based Test ==
== Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====
```

Coverate Rate of Value-at-Risk = 0.05

Number of violations = 111

Empirical frequency of violations = 0.0483

Maximal number of polynomials = 6

Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*** Conditional and Unconditional (p=1) Coverage (UC) Tests **

```
p = 1   J_UC statistic = 0.0818   J_UC pvalue (corrected) = 0.8108
p = 2   J_CC statistic = 1.3765   J_CC pvalue (corrected) = 0.4787
p = 3   J_CC statistic = 1.7580   J_CC pvalue (corrected) = 0.4992
p = 4   J_CC statistic = 1.7605   J_CC pvalue (corrected) = 0.6039
p = 5   J_CC statistic = 1.7681   J_CC pvalue (corrected) = 0.6733
p = 6   J_CC statistic = 2.0367   J_CC pvalue (corrected) = 0.6772
```

*** Independence (IND) Tests **

```
p = 1   J_IND statistic = 0.0103   J_IND pvalue (corrected) = 0.3261
p = 2   J_IND statistic = 1.1169   J_IND pvalue (corrected) = 0.2501
p = 3   J_IND statistic = 1.5610   J_IND pvalue (corrected) = 0.2861
p = 4   J_IND statistic = 1.5629   J_IND pvalue (corrected) = 0.4127
p = 5   J_IND statistic = 1.5682   J_IND pvalue (corrected) = 0.5056
p = 6   J_IND statistic = 1.7549   J_IND pvalue (corrected) = 0.5396
```

A.3.6. BRE

Resultados HS BRE

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi,(2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 137
Empirical frequency of violations = 0.0596
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 4.0527       J_UC pvalue (corrected) = 0.0403
p = 2   J_CC statistic = 55.8645      J_CC pvalue (corrected) = 0.0001
p = 3   J_CC statistic = 76.8155      J_CC pvalue (corrected) = 0.0014
p = 4   J_CC statistic = 118.4500     J_CC pvalue (corrected) = 0.0011
p = 5   J_CC statistic = 131.2604     J_CC pvalue (corrected) = 0.0011
p = 6   J_CC statistic = 150.2422     J_CC pvalue (corrected) = 0.0012

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0087       J_IND pvalue (corrected) = 0.8829
p = 2   J_IND statistic = 96.5504      J_IND pvalue (corrected) = 0.0001
p = 3   J_IND statistic = 286.2460     J_IND pvalue (corrected) = 0.0001
p = 4   J_IND statistic = 762.1447     J_IND pvalue (corrected) = 0.0001
p = 5   J_IND statistic = 827.8823     J_IND pvalue (corrected) = 0.0001
p = 6   J_IND statistic = 1026.2608    J_IND pvalue (corrected) = 0.0001

```

Resultados GARCH BRE

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi,(2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 135
Empirical frequency of violations = 0.0587
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 3.4296   J_UC pvalue (corrected) = 0.0664
p = 2   J_CC statistic = 30.3900   J_CC pvalue (corrected) = 0.0008
p = 3   J_CC statistic = 34.1328   J_CC pvalue (corrected) = 0.0054
p = 4   J_CC statistic = 34.9820   J_CC pvalue (corrected) = 0.0055
p = 5   J_CC statistic = 39.5213   J_CC pvalue (corrected) = 0.0064
p = 6   J_CC statistic = 40.0127   J_CC pvalue (corrected) = 0.0067

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0088   J_IND pvalue (corrected) = 0.8709
p = 2   J_IND statistic = 46.4293   J_IND pvalue (corrected) = 0.0002
p = 3   J_IND statistic = 94.2223   J_IND pvalue (corrected) = 0.0008
p = 4   J_IND statistic = 123.5094   J_IND pvalue (corrected) = 0.0008
p = 5   J_IND statistic = 126.8809   J_IND pvalue (corrected) = 0.0008
p = 6   J_IND statistic = 160.2732   J_IND pvalue (corrected) = 0.0008

```

Resultados CAVIAR BRE

```
=====
== Backtesting Value-at-Risk: A GMM Duration Based Test ==
== Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====
```

Coverate Rate of Value-at-Risk = 0.05

Number of violations = 118

Empirical frequency of violations = 0.0513

Maximal number of polynomials = 6

Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

```
*****
```

```
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
```

```
*****
```

```
p = 1   J_UC statistic = 0.1451   J_UC pvalue (corrected) = 0.7277
p = 2   J_CC statistic = 0.4076   J_CC pvalue (corrected) = 0.8085
p = 3   J_CC statistic = 0.4077   J_CC pvalue (corrected) = 0.9076
p = 4   J_CC statistic = 0.4141   J_CC pvalue (corrected) = 0.9467
p = 5   J_CC statistic = 0.4425   J_CC pvalue (corrected) = 0.9663
p = 6   J_CC statistic = 0.5610   J_CC pvalue (corrected) = 0.9648
```

```
*****
```

```
*** Independence (IND) Tests **
```

```
*****
```

```
p = 1   J_IND statistic = 0.0098   J_IND pvalue (corrected) = 0.5595
p = 2   J_IND statistic = 0.3160   J_IND pvalue (corrected) = 0.5600
p = 3   J_IND statistic = 0.3185   J_IND pvalue (corrected) = 0.7842
p = 4   J_IND statistic = 0.3260   J_IND pvalue (corrected) = 0.8709
p = 5   J_IND statistic = 0.3676   J_IND pvalue (corrected) = 0.9142
p = 6   J_IND statistic = 0.5056   J_IND pvalue (corrected) = 0.9089
```

A.3.7. WTI

Resultados HS WTI

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi,(2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 135
Empirical frequency of violations = 0.0587
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 3.4296   J_UC pvalue (corrected) = 0.0591
p = 2   J_CC statistic = 46.4608   J_CC pvalue (corrected) = 0.0002
p = 3   J_CC statistic = 51.9996   J_CC pvalue (corrected) = 0.0032
p = 4   J_CC statistic = 68.0368   J_CC pvalue (corrected) = 0.0025
p = 5   J_CC statistic = 83.1392   J_CC pvalue (corrected) = 0.0027
p = 6   J_CC statistic = 86.0077   J_CC pvalue (corrected) = 0.0028

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0088   J_IND pvalue (corrected) = 0.8788
p = 2   J_IND statistic = 75.9626   J_IND pvalue (corrected) = 0.0002
p = 3   J_IND statistic = 150.3189   J_IND pvalue (corrected) = 0.0005
p = 4   J_IND statistic = 300.0076   J_IND pvalue (corrected) = 0.0005
p = 5   J_IND statistic = 300.0350   J_IND pvalue (corrected) = 0.0005
p = 6   J_IND statistic = 395.5578   J_IND pvalue (corrected) = 0.0005

```

Resultados GARCH WTI

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 129
Empirical frequency of violations = 0.0561
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 1.8340   J_UC pvalue (corrected) = 0.1791
p = 2   J_CC statistic = 31.2729   J_CC pvalue (corrected) = 0.0005
p = 3   J_CC statistic = 32.2611   J_CC pvalue (corrected) = 0.0053
p = 4   J_CC statistic = 33.6482   J_CC pvalue (corrected) = 0.0053
p = 5   J_CC statistic = 34.7437   J_CC pvalue (corrected) = 0.0064
p = 6   J_CC statistic = 35.8807   J_CC pvalue (corrected) = 0.0068

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0091   J_IND pvalue (corrected) = 0.8248
p = 2   J_IND statistic = 44.4758   J_IND pvalue (corrected) = 0.0002
p = 3   J_IND statistic = 60.0812   J_IND pvalue (corrected) = 0.0014
p = 4   J_IND statistic = 60.3735   J_IND pvalue (corrected) = 0.0014
p = 5   J_IND statistic = 67.7525   J_IND pvalue (corrected) = 0.0015
p = 6   J_IND statistic = 67.8980   J_IND pvalue (corrected) = 0.0016

```

Resultados CAVIAR WTI

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 119
Empirical frequency of violations = 0.0517
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 0.2237   J_UC pvalue (corrected) = 0.6598
p = 2   J_CC statistic = 1.1896   J_CC pvalue (corrected) = 0.5304
p = 3   J_CC statistic = 1.2277   J_CC pvalue (corrected) = 0.6387
p = 4   J_CC statistic = 1.5049   J_CC pvalue (corrected) = 0.6638
p = 5   J_CC statistic = 1.5083   J_CC pvalue (corrected) = 0.7313
p = 6   J_CC statistic = 1.7097   J_CC pvalue (corrected) = 0.7400

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0097   J_IND pvalue (corrected) = 0.6043
p = 2   J_IND statistic = 1.0773   J_IND pvalue (corrected) = 0.2642
p = 3   J_IND statistic = 1.1852   J_IND pvalue (corrected) = 0.3727
p = 4   J_IND statistic = 1.5067   J_IND pvalue (corrected) = 0.4317
p = 5   J_IND statistic = 1.5370   J_IND pvalue (corrected) = 0.5141
p = 6   J_IND statistic = 1.8156   J_IND pvalue (corrected) = 0.5243

```

A.3.8. GAS

Resultados HS GAS

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi,(2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 120
Empirical frequency of violations = 0.0522
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 0.3184   J_UC pvalue (corrected) = 0.5709
p = 2   J_CC statistic = 20.8623   J_CC pvalue (corrected) = 0.0033
p = 3   J_CC statistic = 29.2827   J_CC pvalue (corrected) = 0.0055
p = 4   J_CC statistic = 29.2852   J_CC pvalue (corrected) = 0.0062
p = 5   J_CC statistic = 30.3864   J_CC pvalue (corrected) = 0.0079
p = 6   J_CC statistic = 30.4923   J_CC pvalue (corrected) = 0.0086

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0097   J_IND pvalue (corrected) = 0.6192
p = 2   J_IND statistic = 24.1752   J_IND pvalue (corrected) = 0.0005
p = 3   J_IND statistic = 31.1879   J_IND pvalue (corrected) = 0.0023
p = 4   J_IND statistic = 31.5376   J_IND pvalue (corrected) = 0.0028
p = 5   J_IND statistic = 33.0525   J_IND pvalue (corrected) = 0.0039
p = 6   J_IND statistic = 33.0590   J_IND pvalue (corrected) = 0.0041

```

Resultados GARCH GAS

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelson B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 92
Empirical frequency of violations = 0.0400
Maximal number of polynomials = 6

Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1  J_UC statistic = 5.4533  J_UC pvalue (corrected) = 0.0164
p = 2  J_CC statistic = 8.0896  J_CC pvalue (corrected) = 0.0252
p = 3  J_CC statistic = 8.6058  J_CC pvalue (corrected) = 0.0410
p = 4  J_CC statistic = 8.9372  J_CC pvalue (corrected) = 0.0508
p = 5  J_CC statistic = 9.3471  J_CC pvalue (corrected) = 0.0588
p = 6  J_CC statistic = 9.4942  J_CC pvalue (corrected) = 0.0683

*****
*** Independence (IND) Tests **
*****

p = 1  J_IND statistic = 0.0121  J_IND pvalue (corrected) = 0.0120
p = 2  J_IND statistic = 0.4629  J_IND pvalue (corrected) = 0.4742
p = 3  J_IND statistic = 1.1712  J_IND pvalue (corrected) = 0.3740
p = 4  J_IND statistic = 1.2470  J_IND pvalue (corrected) = 0.5080
p = 5  J_IND statistic = 1.2930  J_IND pvalue (corrected) = 0.5863
p = 6  J_IND statistic = 1.4585  J_IND pvalue (corrected) = 0.6185

```

Resultados CAVIAR GAS

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 116
Empirical frequency of violations = 0.0504
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 0.0378   J_UC pvalue (corrected) = 0.8245
p = 2   J_CC statistic = 0.2260   J_CC pvalue (corrected) = 0.8932
p = 3   J_CC statistic = 1.3755   J_CC pvalue (corrected) = 0.5855
p = 4   J_CC statistic = 1.8443   J_CC pvalue (corrected) = 0.5708
p = 5   J_CC statistic = 1.8559   J_CC pvalue (corrected) = 0.6419
p = 6   J_CC statistic = 2.4176   J_CC pvalue (corrected) = 0.5834

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0099   J_IND pvalue (corrected) = 0.4898
p = 2   J_IND statistic = 0.2026   J_IND pvalue (corrected) = 0.6481
p = 3   J_IND statistic = 1.3892   J_IND pvalue (corrected) = 0.3214
p = 4   J_IND statistic = 1.8387   J_IND pvalue (corrected) = 0.3463
p = 5   J_IND statistic = 1.8593   J_IND pvalue (corrected) = 0.4364
p = 6   J_IND statistic = 2.4733   J_IND pvalue (corrected) = 0.3832

```

A.3.9. CSA

Resultados HS CSA

```

=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi,(2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 115
Empirical frequency of violations = 0.0500
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 0.0100   J_UC pvalue (corrected) = 0.9093
p = 2   J_CC statistic = 19.0808   J_CC pvalue (corrected) = 0.0029
p = 3   J_CC statistic = 19.0816   J_CC pvalue (corrected) = 0.0101
p = 4   J_CC statistic = 20.9822   J_CC pvalue (corrected) = 0.0097
p = 5   J_CC statistic = 21.3235   J_CC pvalue (corrected) = 0.0125
p = 6   J_CC statistic = 26.1633   J_CC pvalue (corrected) = 0.0109

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0100   J_IND pvalue (corrected) = 0.4471
p = 2   J_IND statistic = 19.0808   J_IND pvalue (corrected) = 0.0008
p = 3   J_IND statistic = 19.0816   J_IND pvalue (corrected) = 0.0053
p = 4   J_IND statistic = 20.9822   J_IND pvalue (corrected) = 0.0051
p = 5   J_IND statistic = 21.3235   J_IND pvalue (corrected) = 0.0067
p = 6   J_IND statistic = 26.1633   J_IND pvalue (corrected) = 0.0056

```

Resultados GARCH CSA

```
=====
== Backtesting Value-at-Risk: A GMM Duration Based Test ==
== Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====
```

Coverate Rate of Value-at-Risk = 0.05

Number of violations = 68

Empirical frequency of violations = 0.0296

Maximal number of polynomials = 6

Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

```
*****
```

```
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
```

```
*****
```

```
p = 1   J_UC statistic = 32.2106   J_UC pvalue (corrected) = 0.0001
p = 2   J_CC statistic = 50.2887   J_CC pvalue (corrected) = 0.0001
p = 3   J_CC statistic = 67.9357   J_CC pvalue (corrected) = 0.0015
p = 4   J_CC statistic = 79.0793   J_CC pvalue (corrected) = 0.0015
p = 5   J_CC statistic = 81.2577   J_CC pvalue (corrected) = 0.0017
p = 6   J_CC statistic = 88.2673   J_CC pvalue (corrected) = 0.0020
```

```
*****
```

```
*** Independence (IND) Tests **
```

```
*****
```

```
p = 1   J_IND statistic = 0.0158   J_IND pvalue (corrected) = 0.0001
p = 2   J_IND statistic = 0.0327   J_IND pvalue (corrected) = 0.8704
p = 3   J_IND statistic = 0.0556   J_IND pvalue (corrected) = 0.9712
p = 4   J_IND statistic = 1.0287   J_IND pvalue (corrected) = 0.5773
p = 5   J_IND statistic = 3.3044   J_IND pvalue (corrected) = 0.2263
p = 6   J_IND statistic = 5.2894   J_IND pvalue (corrected) = 0.1263
```

Resultados CAVIAR CSA

```
=====
== Backtesting Value-at-Risk: A GMM Duration Based Test ==
== Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====
```

Coverate Rate of Value-at-Risk = 0.05

Number of violations = 115

Empirical frequency of violations = 0.0500

Maximal number of polynomials = 6

Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*** Conditional and Unconditional (p=1) Coverage (UC) Tests **

```
p = 1   J_UC statistic = 0.0100   J_UC pvalue (corrected) = 0.8887
p = 2   J_CC statistic = 0.9714   J_CC pvalue (corrected) = 0.6005
p = 3   J_CC statistic = 1.1990   J_CC pvalue (corrected) = 0.6444
p = 4   J_CC statistic = 1.5073   J_CC pvalue (corrected) = 0.6584
p = 5   J_CC statistic = 1.6585   J_CC pvalue (corrected) = 0.6955
p = 6   J_CC statistic = 2.2713   J_CC pvalue (corrected) = 0.6180
```

*** Independence (IND) Tests **

```
p = 1   J_IND statistic = 0.0100   J_IND pvalue (corrected) = 0.4464
p = 2   J_IND statistic = 0.9714   J_IND pvalue (corrected) = 0.2899
p = 3   J_IND statistic = 1.1990   J_IND pvalue (corrected) = 0.3648
p = 4   J_IND statistic = 1.5073   J_IND pvalue (corrected) = 0.4259
p = 5   J_IND statistic = 1.6585   J_IND pvalue (corrected) = 0.4846
p = 6   J_IND statistic = 2.2713   J_IND pvalue (corrected) = 0.4239
```

A.3.10. CEU

Resultados HS CEU

```
=====
==  Backtesting Value-at-Risk: A GMM Duration Based Test  ==
==  Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi,(2011) ==
=====

Coverate Rate of Value-at-Risk = 0.05
Number of violations = 116
Empirical frequency of violations = 0.0504
Maximal number of polynomials = 6
Sample size = 2300

Number of simulations (for Dufour's correction)= 9999

*****
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
*****

p = 1   J_UC statistic = 0.0378   J_UC pvalue (corrected) = 0.8235
p = 2   J_CC statistic = 18.5018   J_CC pvalue (corrected) = 0.0035
p = 3   J_CC statistic = 22.6545   J_CC pvalue (corrected) = 0.0078
p = 4   J_CC statistic = 22.7714   J_CC pvalue (corrected) = 0.0092
p = 5   J_CC statistic = 31.2571   J_CC pvalue (corrected) = 0.0085
p = 6   J_CC statistic = 34.3011   J_CC pvalue (corrected) = 0.0082

*****
*** Independence (IND) Tests **
*****

p = 1   J_IND statistic = 0.0099   J_IND pvalue (corrected) = 0.4861
p = 2   J_IND statistic = 19.1190   J_IND pvalue (corrected) = 0.0011
p = 3   J_IND statistic = 24.0028   J_IND pvalue (corrected) = 0.0040
p = 4   J_IND statistic = 24.1887   J_IND pvalue (corrected) = 0.0044
p = 5   J_IND statistic = 33.3567   J_IND pvalue (corrected) = 0.0044
p = 6   J_IND statistic = 36.1712   J_IND pvalue (corrected) = 0.0040
```

Resultados GARCH CEU

```
=====
== Backtesting Value-at-Risk: A GMM Duration Based Test ==
== Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====
```

```
Coverate Rate of Value-at-Risk = 0.05
Number of violations = 87
Empirical frequency of violations = 0.0378
Maximal number of polynomials = 6
Sample size = 2300
```

```
Number of simulations (for Dufour's correction)= 9999
```

```
*****
```

```
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
```

```
*****
```

```
p = 1   J_UC statistic = 8.6878      J_UC pvalue (corrected) = 0.0034
p = 2   J_CC statistic = 78.8073     J_CC pvalue (corrected) = 0.0001
p = 3   J_CC statistic = 79.3745     J_CC pvalue (corrected) = 0.0012
p = 4   J_CC statistic = 83.2012     J_CC pvalue (corrected) = 0.0016
p = 5   J_CC statistic = 87.6276     J_CC pvalue (corrected) = 0.0018
p = 6   J_CC statistic = 100.8399    J_CC pvalue (corrected) = 0.0017
```

```
*****
```

```
*** Independence (IND) Tests **
```

```
*****
```

```
p = 1   J_IND statistic = 0.0127     J_IND pvalue (corrected) = 0.0019
p = 2   J_IND statistic = 17.7358    J_IND pvalue (corrected) = 0.0015
p = 3   J_IND statistic = 26.3654    J_IND pvalue (corrected) = 0.0032
p = 4   J_IND statistic = 26.8652    J_IND pvalue (corrected) = 0.0037
p = 5   J_IND statistic = 26.9150    J_IND pvalue (corrected) = 0.0057
p = 6   J_IND statistic = 27.8991    J_IND pvalue (corrected) = 0.0057
```

Resultados CAVIAR CEU

```
=====
== Backtesting Value-at-Risk: A GMM Duration Based Test ==
== Candelon B., C. Colletaz, C. Hurlin and S. Tokpavi, (2011) ==
=====
```

```
Coverate Rate of Value-at-Risk = 0.05
Number of violations = 117
Empirical frequency of violations = 0.0509
Maximal number of polynomials = 6
Sample size = 2300
```

```
Number of simulations (for Dufour's correction)= 9999
```

```
*****
```

```
*** Conditional and Unconditional (p=1) Coverage (UC) Tests **
```

```
*****
```

```
p = 1 J_UC statistic = 0.0830 J_UC pvalue (corrected) = 0.7572
p = 2 J_CC statistic = 0.0835 J_CC pvalue (corrected) = 0.9639
p = 3 J_CC statistic = 0.4364 J_CC pvalue (corrected) = 0.8946
p = 4 J_CC statistic = 0.7623 J_CC pvalue (corrected) = 0.8611
p = 5 J_CC statistic = 0.8591 J_CC pvalue (corrected) = 0.8802
p = 6 J_CC statistic = 0.9196 J_CC pvalue (corrected) = 0.9065
```

```
*****
```

```
*** Independence (IND) Tests **
```

```
*****
```

```
p = 1 J_IND statistic = 0.0099 J_IND pvalue (corrected) = 0.5312
p = 2 J_IND statistic = 0.0109 J_IND pvalue (corrected) = 0.9697
p = 3 J_IND statistic = 0.4052 J_IND pvalue (corrected) = 0.7138
p = 4 J_IND statistic = 0.7278 J_IND pvalue (corrected) = 0.6854
p = 5 J_IND statistic = 0.8102 J_IND pvalue (corrected) = 0.7319
p = 6 J_IND statistic = 0.8678 J_IND pvalue (corrected) = 0.7938
```

A.4. Resultados Gráficos Data Total

A.4.1. EUR




Figura A.21: Resultado HS para EUR




Figura A.22: Resultado GARCH para EUR




Figura A.23: Resultado CAVIAR para EUR

A.4.2. LIB




Figura A.24: Resultado HS para LIB




Figura A.25: Resultado GARCH para LIB




Figura A.26: Resultado CAVIAR para LIB

A.4.3. SIL




Figura A.27: Resultado HS para SIL




Figura A.28: Resultado GARCH para SIL




Figura A.29: Resultado CAVIAR para SIL

A.4.4. GOL




Figura A.30: Resultado HS para GOL




Figura A.31: Resultado GARCH para GOL




Figura A.32: Resultado CAVIAR para GOL

A.4.5. COP




Figura A.33: Resultado HS para COP




Figura A.34: Resultado GARCH para COP




Figura A.35: Resultado CAVIAR para COP

A.4.6. BRE




Figura A.36: Resultado HS para BRE




Figura A.37: Resultado GARCH para BRE




Figura A.38: Resultado CAVIAR para BRE

A.4.7. WTI




Figura A.39: Resultado HS para WTI




Figura A.40: Resultado GARCH para WTI




Figura A.41: Resultado CAVIAR para WTI

A.4.8. GAS




Figura A.42: Resultado HS para GAS




Figura A.43: Resultado GARCH para GAS




Figura A.44: Resultado CAVIAR para GAS

A.4.9. CSA




Figura A.45: Resultado HS para CSA




Figura A.46: Resultado GARCH para CSA







Figura A.47: Resultado CAVIAR para CSA

A.4.10. CEU**Figura A.48:** Resultado HS para CEU**Figura A.49:** Resultado GARCH para CEU**Figura A.50:** Resultado CAVIAR para CEU