

**UNIVERSIDAD NACIONAL DE ROSARIO**  
**FACULTAD DE CIENCIAS ECONÓMICAS Y**  
**ESTADÍSTICA**

**CARRERA DE POSGRADO**  
**MAESTRÍA EN ESTADÍSTICA APLICADA**

**Evaluación de pronósticos para la volatilidad  
empleando modelos autorregresivos con  
heterocedasticidad condicional generalizados  
aplicados a precios diarios de acciones en Argentina**

Autor: Luis Damiano

Director: Mg. María Teresa Blaconá

2017

TRIBUNAL EXAMINADOR:

Lic. Patricia Botargues

Mg. Fernanda Méndez

Mg. Javier Bussi

*Dedicado a todos aquellos que me acompañan en este camino que aún tiene  
tanto por recorrer...*

# Agradecimientos

A mi esposa, por apoyarme, quererme y hacerme tan feliz.  
A mi familia, por el inmenso cariño y el apoyo incondicional.  
A mi directora de tesis, por la dedicación a la hora de guiar mi investigación.  
A mis amigos, por ayudarme a crecer como persona.  
A mis compañeros, por los gratos momentos compartidos.  
A mis profesores, por alimentar mi voraz curiosidad.  
A mis mentores, por permitirme lograr aquello que yo solo no podría.  
Y, por último, a todos aquellos que tanto creen en mí.

# Resumen

Esta tesis trata sobre los hechos estilizados de los retornos y la volatilidad, los modelos de heterocedasticidad condicional, las funciones de densidad habitualmente empleadas junto a ellos, el diagnóstico de residuos y la evaluación de pronósticos fuera de la muestra. El abordaje no es sólo teórico, sino que además propone una aplicación para la serie de precios de las once acciones más líquidas de Argentina y el Índice Merval (2009-2016).

La leptocurtosis se impone como la característica más determinante y la principal falla al supuesto de densidad gaussiana. La asimetría juega un rol más acotado y sólo atenta contra la aproximación normal en determinados casos. El efecto apalancamiento, muy difundido en investigaciones para otros mercados, es observado sólo en circunstancias muy particulares.

Partiendo de un modelo  $ARCH(1,1) - GARCH(1,1)$  con densidad gaussiana, se diagnostican los residuos y se proponen variantes según las falencias detectadas. Los criterios de información tienden a seleccionar la especificación GARCH y la distribución generalizada del error, tanto simétrica como asimétrica. Si bien estos nuevos modelos resuelven algunas de las limitaciones identificadas, no presentan necesariamente un mayor poder predictivo fuera de la muestra. Los estadísticos direccionales y las medidas de error medio de pronóstico resultan muy similares, aunque la cantidad de excesos al VaR mejora en la mitad de los casos. La penalización de los criterios de información no siempre es suficiente para evitar el sobreajuste.

Palabras claves: retornos, volatilidad, hechos estilizados, asimetría, leptocurtosis, heterocedasticidad condicional, EGARCH, GJRGARCH, TGARCH, NGARCH, generalizada del error, pronósticos fuera de la muestra.

# Índice general

<b>Agradecimientos</b>	<b>III</b>
<b>Resumen</b>	<b>IV</b>
<b>Índice de figuras</b>	<b>X</b>
<b>Índice de cuadros</b>	<b>XII</b>
<b>1. Introducción</b>	<b>1</b>
<b>2. Retornos y volatilidad</b>	<b>5</b>
2.1. Hechos estilizados . . . . .	5
2.1.1. Dependencia . . . . .	6
2.1.2. Distribución paramétrica . . . . .	9
2.1.3. Predictibilidad de la volatilidad . . . . .	12
2.1.4. El desafío de los hechos estilizados . . . . .	13
2.2. Volatilidad . . . . .	13
2.2.1. Estimador de cierre a cierre . . . . .	15
2.2.2. Estimador de Parkinson . . . . .	19
2.2.3. Estimador de Garman-Klass . . . . .	21
2.2.4. Estimador de Rogers-Satchell . . . . .	22
2.2.5. Estimador de Yang-Zhang . . . . .	22
2.2.6. Elección del estimador . . . . .	23
<b>3. Modelos de heterocedasticidad condicional</b>	<b>25</b>
3.1. Modelos para la volatilidad . . . . .	25

3.1.1.	Modelo ARCH . . . . .	26
3.1.2.	Modelo GARCH . . . . .	27
3.1.3.	Modelo EGARCH . . . . .	28
3.1.4.	Modelo GJRGARCH . . . . .	28
3.1.5.	Modelo TGARCH . . . . .	29
3.1.6.	Modelo NGARCH . . . . .	29
3.1.7.	La curva de impacto de noticias . . . . .	30
3.1.8.	Pronósticos . . . . .	31
3.1.9.	Elección del modelo . . . . .	33
3.2.	Función de densidad . . . . .	34
3.2.1.	Distribución gaussiana . . . . .	34
3.2.2.	Distribución t de Student . . . . .	35
3.2.3.	Distribución generalizada del error . . . . .	35
3.2.4.	Asimetría . . . . .	36
3.2.5.	Estimación máxima verosímil . . . . .	37
<b>4.</b>	<b>Evaluación de pronósticos</b>	<b>39</b>
4.1.	Variable a pronosticar . . . . .	40
4.2.	Función de pérdida . . . . .	40
4.3.	Estimadores imperfectos de la volatilidad . . . . .	44
4.4.	Comparación de pronósticos . . . . .	47
4.4.1.	Pruebas de Diebold-Mariano . . . . .	48
4.4.2.	Pruebas de ortogonalidad . . . . .	52
<b>5.</b>	<b>Aplicación al mercado de acciones en Argentina</b>	<b>54</b>
5.1.	Introducción . . . . .	54
5.2.	Hechos estilizados . . . . .	55
5.2.1.	Dependencia . . . . .	55
5.2.2.	Distribución paramétrica . . . . .	57
5.3.	Análisis de modelos . . . . .	58
5.3.1.	Estimación de la volatilidad . . . . .	58
5.3.2.	Modelos de heterocedasticidad condicional . . . . .	59
5.3.3.	Diagnóstico de residuos . . . . .	60

5.3.4. Evaluación de pronósticos . . . . .	61
5.4. Casos de aplicación . . . . .	61
5.4.1. APBR . . . . .	62
5.4.2. BMA . . . . .	63
5.4.3. COME . . . . .	64
5.4.4. EDN . . . . .	66
5.4.5. ERAR . . . . .	67
5.4.6. FRAN . . . . .	68
5.4.7. GGAL . . . . .	69
5.4.8. MERVAL . . . . .	71
5.4.9. PAMP . . . . .	72
5.4.10. TECO2 . . . . .	73
5.4.11. TS . . . . .	74
5.4.12. YPFD . . . . .	76
<b>6. Consideraciones finales</b>	<b>79</b>
<b>Bibliografía</b>	<b>92</b>
<b>A. Hechos estilizados sobre los retornos y la volatilidad</b>	<b>92</b>
A.1. Retornos (datos originales) . . . . .	92
A.2. Retornos (APBR) . . . . .	93
A.3. Retornos (BMA) . . . . .	94
A.4. Retornos (COME) . . . . .	95
A.5. Retornos (EDN) . . . . .	96
A.6. Retornos (ERAR) . . . . .	97
A.7. Retornos (FRAN) . . . . .	98
A.8. Retornos (GGAL) . . . . .	99
A.9. Retornos (MERVAL) . . . . .	100
A.10. Retornos (PAMP) . . . . .	101
A.11. Retornos (TECO2) . . . . .	102
A.12. Retornos (TS) . . . . .	103
A.13. Retornos (YPFD) . . . . .	104
A.14. Estimadores de la volatilidad (APBR) . . . . .	105



A.15. Estimadores de la volatilidad (BMA)	106
A.16. Estimadores de la volatilidad (COME)	107
A.17. Estimadores de la volatilidad (EDN)	108
A.18. Estimadores de la volatilidad (ERAR)	109
A.19. Estimadores de la volatilidad (FRAN)	110
A.20. Estimadores de la volatilidad (GGAL)	111
A.21. Estimadores de la volatilidad (MERVAL)	112
A.22. Estimadores de la volatilidad (PAMP)	113
A.23. Estimadores de la volatilidad (TECO2)	114
A.24. Estimadores de la volatilidad (TS)	115
A.25. Estimadores de la volatilidad (YPDF)	116
<b>B. Análisis de modelos</b>	<b>117</b>
B.1. Diagnóstico y evaluación de pronósticos (APBR)	117
B.2. Diagnóstico y evaluación de pronósticos (BMA)	119
B.3. Diagnóstico y evaluación de pronósticos (COME)	121
B.4. Diagnóstico y evaluación de pronósticos (EDN)	123
B.5. Diagnóstico y evaluación de pronósticos (ERAR)	125
B.6. Diagnóstico y evaluación de pronósticos (FRAN)	127
B.7. Diagnóstico y evaluación de pronósticos (GGAL)	129
B.8. Diagnóstico y evaluación de pronósticos (MERVAL)	131
B.9. Diagnóstico y evaluación de pronósticos (PAMP)	133
B.10. Diagnóstico y evaluación de pronósticos (TECO2)	135
B.11. Diagnóstico y evaluación de pronósticos (TS)	137
B.12. Diagnóstico y evaluación de pronósticos (YPDF)	139

# Índice de figuras

5.1. Valores extremos (YPPFD). . . . .	57
5.2. Volatilidad de COME (transversal). . . . .	59
5.3. Autocorrelación de residuos (COME). . . . .	65
5.4. Distribución de residuos (ERAR). . . . .	68
5.5. Value At Risk (TS). . . . .	76
A.1. Análisis exploratorio (APBR). . . . .	93
A.2. Análisis exploratorio (BMA). . . . .	94
A.3. Análisis exploratorio (COME). . . . .	95
A.4. Análisis exploratorio (EDN). . . . .	96
A.5. Análisis exploratorio (ERAR). . . . .	97
A.6. Análisis exploratorio (FRAN). . . . .	98
A.7. Análisis exploratorio (GGAL). . . . .	99
A.8. Análisis exploratorio (MERVAL). . . . .	100
A.9. Análisis exploratorio (PAMP). . . . .	101
A.10. Análisis exploratorio (TECO2). . . . .	102
A.11. Análisis exploratorio (TS). . . . .	103
A.12. Análisis exploratorio (YPPFD). . . . .	104
A.13. Volatilidad de APBR (serie de tiempo). . . . .	105
A.14. Volatilidad de APBR (transversal). . . . .	105
A.15. Volatilidad de BMA (serie de tiempo). . . . .	106
A.16. Volatilidad de BMA (transversal). . . . .	106
A.17. Volatilidad de COME (serie de tiempo). . . . .	107
A.18. Volatilidad de COME (transversal). . . . .	107

A.19.Volatilidad de EDN (serie de tiempo).	108
A.20.Volatilidad de EDN (transversal).	108
A.21.Volatilidad de ERAR (serie de tiempo).	109
A.22.Volatilidad de ERAR (transversal).	109
A.23.Volatilidad de FRAN (serie de tiempo).	110
A.24.Volatilidad de FRAN (transversal).	110
A.25.Volatilidad de GGAL (serie de tiempo).	111
A.26.Volatilidad de GGAL (transversal).	111
A.27.Volatilidad de MERVAL (serie de tiempo).	112
A.28.Volatilidad de MERVAL (transversal).	112
A.29.Volatilidad de PAMP (serie de tiempo).	113
A.30.Volatilidad de PAMP (transversal).	113
A.31.Volatilidad de TECO2 (serie de tiempo).	114
A.32.Volatilidad de TECO2 (transversal).	114
A.33.Volatilidad de TS (serie de tiempo).	115
A.34.Volatilidad de TS (transversal).	115
A.35.Volatilidad de YPFD (serie de tiempo).	116
A.36.Volatilidad de YPFD (transversal).	116
B.1. Diagnóstico de residuos y evaluación de pronósticos (APBR).	117
B.2. Diagnóstico de residuos y evaluación de pronósticos (BMA).	119
B.3. Diagnóstico de residuos y evaluación de pronósticos (COME).	121
B.4. Diagnóstico de residuos y evaluación de pronósticos (EDN).	123
B.5. Diagnóstico de residuos y evaluación de pronósticos (ERAR).	125
B.6. Diagnóstico de residuos y evaluación de pronósticos (FRAN).	127
B.7. Diagnóstico de residuos y evaluación de pronósticos (GGAL).	129
B.8. Diagnóstico de residuos y evaluación de pronósticos (MERVAL).	131
B.9. Diagnóstico de residuos y evaluación de pronósticos (PAMP).	133
B.10. Diagnóstico de residuos y evaluación de pronósticos (TECO2).	135
B.11. Diagnóstico de residuos y evaluación de pronósticos (TS).	137
B.12. Diagnóstico de residuos y evaluación de pronósticos (YPFD).	139

# Índice de cuadros

2.1. Estimadores de la volatilidad . . . . .	23
5.1. Estadísticos resumen para los retornos (datos truncados al 1 %). . . . .	56
5.2. Resumen de la evaluación de pronósticos . . . . .	78
A.1. Estadísticos resumen para los retornos (datos originales). . . . .	92
A.2. Correlación entre estimadores para APBR (datos originales). . . . .	105
A.3. Correlación entre estimadores para APBR (datos truncados al 1 %). . . . .	105
A.4. Correlación entre estimadores para BMA (datos originales). . . . .	106
A.5. Correlación entre estimadores para BMA (datos truncados al 1 %). . . . .	106
A.6. Correlación entre estimadores para COME (datos originales). . . . .	107
A.7. Correlación entre estimadores para COME (datos truncados al 1 %). . . . .	107
A.8. Correlación entre estimadores para EDN (datos originales). . . . .	108
A.9. Correlación entre estimadores para EDN (datos truncados al 1 %). . . . .	108
A.10. Correlación entre estimadores para ERAR (datos originales). . . . .	109
A.11. Correlación entre estimadores para ERAR (datos truncados al 1 %). . . . .	109
A.12. Correlación entre estimadores para FRAN (datos originales). . . . .	110
A.13. Correlación entre estimadores para FRAN (datos truncados al 1 %). . . . .	110
A.14. Correlación entre estimadores para GGAL (datos originales). . . . .	111
A.15. Correlación entre estimadores para GGAL (datos truncados al 1 %). . . . .	111
A.16. Correlación entre estimadores para Merval (datos originales). . . . .	112
A.17. Correlación entre estimadores para Merval (datos truncados al 1 %). . . . .	112
A.18. Correlación entre estimadores para PAMP (datos originales). . . . .	113
A.19. Correlación entre estimadores para PAMP (datos truncados al 1 %). . . . .	113

A.20. Correlación entre estimadores para TECO2 (datos originales). . .	114
A.21. Correlación entre estimadores para TECO2 (datos truncados al 1 %). . . . .	114
A.22. Correlación entre estimadores para TS (datos originales). . . . .	115
A.23. Correlación entre estimadores para TS (datos truncados al 1 %). . .	115
A.24. Correlación entre estimadores para YPFD (datos originales). . . .	116
A.25. Correlación entre estimadores para YPFD (datos truncados al 1 %).	116
B.1. Estadísticos resumen de los residuos y los pronósticos (APBR). . .	118
B.2. Estadísticos resumen de los residuos y los pronósticos (BMA). . .	120
B.3. Estadísticos resumen de los residuos y los pronósticos (COME). . .	122
B.4. Estadísticos resumen de los residuos y los pronósticos (EDN). . .	124
B.5. Estadísticos resumen de los residuos y los pronósticos (ERAR). . .	126
B.6. Estadísticos resumen de los residuos y los pronósticos (FRAN). . .	128
B.7. Estadísticos resumen de los residuos y los pronósticos (GGAL). . .	130
B.8. Estadísticos resumen de los residuos y los pronósticos (MERVAL). .	132
B.9. Estadísticos resumen de los residuos y los pronósticos (PAMP). . .	134
B.10. Estadísticos resumen de los residuos y los pronósticos (TECO2). . .	136
B.11. Estadísticos resumen de los residuos y los pronósticos (TS). . . . .	138
B.12. Estadísticos resumen de los residuos y los pronósticos (YPFD). . .	140

# Capítulo 1

## Introducción

La volatilidad es el grado de variación que el precio de una acción tiene a lo largo del tiempo. Es una medida de riesgo y su importancia está dada por la prima exigida por los agentes económicos para invertir en activos riesgosos. Se trata de un concepto central en la teoría financiera, y toma mayor presencia en tópicos como la administración del riesgo, la valuación de activos y la construcción de portafolios.

La volatilidad es un fenómeno no observable y, por lo tanto, de difícil medición. Su estimación es importante para académicos y profesionales, tanto a los fines de evaluar si teoría financiera explica razonablemente los fenómenos observados como también para aplicarla en estrategias de *trading* o cobertura. En las últimas décadas, la literatura se ha nutrido de intentos por diseñar estimadores más eficientes que el desvío estándar de los retornos (Parkinson, 1980, Garman y Klass, 1980, Rogers y Satchell, 1991, Rogers *et al.*, 1994, Yang y Zhang, 2000). Aunque tienen mejores propiedades teóricas, los trabajos empíricos cuestionan que los supuestos empleados sean realistas.

Además de una medición precisa, resulta muy importante contar con modelos para describir su comportamiento y pronosticar observaciones futuras. Numerosos estudios empíricos lograron detectar ciertas características propias de la volatilidad que se presentan a lo largo de diferentes mercados y períodos de tiempo (Mandelbrot, 1971, Cont, 2001, Granger y Ding, 1994). La teoría financiera se ha enriquecido con una gran cantidad de modelos, que a su vez dieron ori-

gen a diversas variantes que conforman familias de modelos, con el objetivo de capturar, replicar y aprovechar estos hechos estilizados para pronosticar.

El modelo autoregresivo con heterocedasticidad condicional tuvo un gran impacto en la econometría financiera (Engle, 1982). Muy rápidamente proliferaron desarrollos teóricos con las propiedades matemáticas, adaptaciones para resolver las falencias que los profesionales observaban en su práctica diaria y generalizaciones (Bollerslev, 1986, 1987, Pagan y Schwert, 1990, Nelson, 1991, Higgins y Bera, 1992, Engle y Ng, 1993, Rabemananjara y Zakoian, 1993). Algunos investigadores prestaron especial atención al problema del pronóstico, incluyendo el cálculo, la medición del error, la comparación de modelos y las pruebas de hipótesis (Diebold y Mariano, 1995, Andersen y Bollerslev, 1998, Engle y Patton, 2001, Andersen *et al.*, 2003, Poon, 2005, West, 1996, West y McCracken, 1998, Hansen y Lunde, 2006, Patton, 2011, Diebold, 2012).

Esta temática excede el interés meramente académico y tiene un fuerte impacto en el desarrollo de la práctica profesional de los agentes económicos en general y los agentes del mercado en particular. La prueba está en la larga lista de textos de econometría financiera que se enfocan más bien en las cuestiones de aplicación (Taylor, 1986, Campbell *et al.*, 1997, Franke *et al.*, 2004, Ruppert, 2004, Zivot y Wang, 2007, Brooks, 2008, Lai y Xing, 2008, Andersen *et al.*, 2009, Tsay, 2010, Daniélsson, 2011, Taylor, 2005, Sinclair, 2013, Franses *et al.*, 2014).

Esta tesis comienza con un repaso de los puntos más sobresalientes que hacen a los hechos estilizados de los retornos y los estimadores de la volatilidad para luego considerar en profundidad las diferentes construcciones matemáticas propuestas en la literatura. La bondad de ajuste y la precisión de los pronóstico son evaluadas en términos absolutos y relativos a fin de identificar de qué forma la mayor complejidad se traduce en más y mejor información para el pronosticador.

Se presenta un abordaje teórico así como también una aplicación para el precio de las acciones en Argentina. La proporción de teoría y práctica volcada intenta demostrar que el tema elegido resulta igual de rico para un análisis académico como profesional.

El [Capítulo 2](#) comienza con una pequeña descripción de los principales hechos estilizados que la teoría financiera acumula luego de muchos años de estudios

empíricos sobre el precio de las acciones. A continuación, se introduce el problema de la estimación de la volatilidad, se define un conjunto de estimadores y luego se finaliza con algunas consideraciones sobre su elección.

El [Capítulo 3](#) presenta los principales miembros de la familia de modelos de heterocedasticidad condicional. Se introducen seis formas alternativas de especificar la ecuación de volatilidad, todas ellas concebidas a partir de los hechos estilizados descritos anteriormente. También se consideran tres funciones de densidad en sus variantes simétrica y asimétrica que más adelante serán empleadas para obtener la estimación máxima verosímil.

El [Capítulo 4](#) trata sobre la evaluación de los pronósticos. Se desarrollan los principales aspectos que hacen al proceso de evaluación, incluyendo la elección de la variable a pronosticar y la función de pérdida. Se analizan las dificultades propias de evaluar el pronóstico de una variable que no es observable y se mencionan diferentes pruebas de hipótesis que comparan los resultados de dos o más modelos.

El [Capítulo 5](#) aplica la teoría a las series diaria de precios de las acciones más líquidas en Argentina y el Índice Merval para un período de aproximadamente seis años. Los análisis realizados para cada uno de los doce individuos incluyen el estudio de los hechos estilizados en el mercado local, la estimación de la volatilidad, la estimación de modelos, el diagnóstico de residuos y la evaluación de los pronósticos.

El [Capítulo 6](#) trata las conclusiones e intenta dar una primera respuesta a los interrogantes que motivan esta tesis. Además, incluye propuestas para profundizar en un futuro los tópicos revisados.

Finalmente, el [Anexo A](#) y el [Anexo B](#) documentan exhaustivamente todos los análisis que dan soporte a las conclusiones. No se trata de una sección meramente documental: su contenido incluye una gran variedad de cuadros y figuras con la intención de brindar algunas herramientas para que el lector pueda responder aquellas preguntas que no hayan sido directamente tratadas en este trabajo.

## **Objetivos**

La presente tesis tiene como objetivos:



- Revisar metodológicamente los conceptos necesarios para evaluar el pronóstico de la volatilidad.
- Explorar en qué grado los hechos estilizados relevados a lo largo de la literatura financiera se verifican en el mercado argentino.
- Identificar en qué grado complejizar los modelos de la volatilidad mejoran su capacidad predictiva.

# Capítulo 2

## Retornos y volatilidad

Esta sección comienza con un breve resumen de los principales hechos estilizados para los retornos y la volatilidad según la literatura vigente. Para un mayor grado de detalle, se recomienda la revisión realizada por [Cont \(2001\)](#).

### Notación

Sea  $P_t$  el precio de un activo al cierre del día de negociación  $t$ . Se define como retorno logarítmico a la tasa de su variación compuesta en tiempo continuo, es decir  $r_t = \ln(P_t/P_{t-1})$ . Siempre que se mencione el retorno, se entenderá que está en escala logarítmica. Sea  $\mathcal{F}_{t-1}$  el conjunto de información disponible al momento  $t - 1$ , el cual está conformado por todas las funciones lineales de los retornos pasados e incluye  $\hat{\sigma}(r_{t-j})$  para  $j \geq 1$  entre otros. Llámese media condicional a

$$E \langle r_t | \mathcal{F}_{t-1} \rangle \equiv E_{t-1} \langle r_t \rangle \equiv \mu_t, \quad (2.1)$$

y variancia condicional a

$$V \langle r_t | \mathcal{F}_{t-1} \rangle \equiv V_{t-1} \langle r_t \rangle \equiv \sigma_t^2. \quad (2.2)$$

### 2.1. Hechos estilizados

En el estudio de datos financieros, se define a los hechos estilizados como aquellas características que resultan lo suficientemente consistentes para ser generalmente aceptadas como verdaderas. Los agentes económicos habitualmente

estudian el mercado mediante un enfoque basado en eventos, de forma que los movimientos en los precios suelen ser explicados y racionalizados en conexión a noticias conocidas en un momento dado. Aunque los distintos activos, mercados y períodos de tiempo reaccionan en forma diferente ante la llegada de nueva información, se observa cierta regularidad en las series de precios.

Numerosos estudios econométricos han identificado similitudes en diversas series de tiempo financieras, incluyendo precios de acciones, bonos, divisas y tasas de interés. Más específicamente, la variación en el precio de las acciones comparte numerosas propiedades estadísticas no triviales. Estas generalidades permiten explotar las similitudes a cambio de perder cierta habilidad para hacer observaciones precisas. El consenso indica que resulta difícil incorporar todas estas características en los modelos econométricos, e incluso en numerosas ocasiones resulta difícil distinguir entre diferentes explicaciones que compiten para dar cuenta de uno o más fenómenos relacionados.

### 2.1.1. Dependencia

Es usual estudiar el cambio en los precios a través de la función de autocorrelación

$$\rho(\tau) = \text{corr}(r_t, r_{t+\tau}), \quad (2.3)$$

donde  $\tau$  representa el rezago. En mercados líquidos, los retornos no observan autocorrelación lineal significativa para series de tiempo muestreadas con una frecuencia mayor a los 20 minutos, umbral debajo del cual se manifiestan los efectos de la microestructura de los mercados. Este hecho es conocido y fue ampliamente documentado como argumento en favor de la hipótesis de los mercados eficientes: una correlación significativa en la variación en los precios permitiría ejecutar estrategias de arbitraje estadístico, salvo para intervalos muy pequeños que representan el tiempo de respuesta de los agentes ante la llegada de información. Las herramientas de procesamiento de señales basadas en propiedades de segundo orden, incluyendo los dominios de tiempo y espectro, no pueden diferenciar el retorno de los activos del ruido blanco. En palabras de Mandelbrot, el arbitraje blanquea el espectro de la variación en los precios ([Mandelbrot, 1971](#)).

Algunos autores intentaron considerar este hecho como evidencia a favor de

los modelos de caminata aleatoria, los cuales consideran que los retornos son variables aleatorias independientes. En realidad, el supuesto de independencia es mucho más amplio pues requiere que cualquier función no lineal de los retornos esté exentas de correlación. Muchas transformaciones no lineales de los retornos muestran correlación positiva, como ser la segunda potencia o su valor absoluto

$$\rho_2(\tau) = \text{corr}(|r_t|^2, |r_{t+\tau}|^2). \quad (2.4)$$

Un gran número de trabajos empíricos encuentran que la función de autocorrelación del cuadrado de los retornos es positiva y decae lentamente, siendo significativa para varios días e incluso semanas hacia atrás. Este análisis puede generalizarse a través de una función de potencia

$$\rho_\alpha(\tau) = \text{corr}(|r_t|^\alpha, |r_{t+\tau}|^\alpha), \quad (2.5)$$

donde la correlación para un rezago dado  $\tau$  se maximiza en  $\alpha = 1$ , fenómeno que [Ding \*et al.\* \(1993\)](#) y [Granger y Ding \(1994\)](#) decidieron llamar el efecto de Taylor por haber sido presentado en primera oportunidad en [Taylor \(1986\)](#). De esta manera, los retornos absolutos son los más predecibles. Algunos autores proponen el uso del análisis de correlación canónica no lineal para identificar aquella transformación de los retornos que maximiza la correlación para el primer rezago ([Darolles \*et al.\*, 1999](#)).

Este hecho es conocido como persistencia ya que movimientos en la volatilidad ocurridos en un momento ejercen influencia sobre la volatilidad esperada para varios períodos en el futuro, y manifiesta la existencia de conglomerados en la volatilidad. Adicionalmente, las transformaciones mencionadas exhiben características propias de los procesos de memoria larga, donde la autocorrelación se mantiene significativa por un número mayor de rezagos respecto de la tasa exponencial de los procesos ARMA.

En resumen, la ausencia de correlación en los retornos más la dependencia no lineal se expresa como

$$r_t = \sigma_t \epsilon_t, \quad (2.6)$$

donde  $\epsilon_t$  es ruido blanco y  $\sigma_t$  es un factor de volatilidad condicional cuya dinámica se debe modelar respetando las observaciones empíricas. Es importante destacar

que esta última medida y su autocorrelación no son directamente observables, por lo tanto la definición de volatilidad queda supeditada al modelo empleado.

El efecto apalancamiento es otra forma de dependencia no lineal en los retornos. Es definido como la correlación entre un retorno y el cuadrado del subsecuente

$$L_\tau = \text{corr} \left( r_t, |r_{t+\tau}|^2 \right). \quad (2.7)$$

Usualmente comienza con un valor negativo y decae hacia cero, sugiriendo que una variación negativa en el precio incrementa la volatilidad de forma asimétrica pues  $L_\tau \neq L_{-\tau}$ .

A la hora de verificar la asimetría en la volatilidad, [Engle y Ng \(1993\)](#) proponen un conjunto de pruebas de hipótesis de sesgo en el signo y en el tamaño. Éstas se aplican usualmente sobre los residuos de un modelo GARCH simétrico a fin de diagnosticar la eventual falta de especificación. Sea  $a_t$  la perturbación de un modelo para la media,  $z_t = a_t/h_t$  su versión estandarizada. Se definen las variables indicadoras en función del signo de la perturbación correspondiente al período anterior  $S_{t-1}^- = \mathbb{I}_{(a_{t-1} < 0)}$  y  $S_{t-1}^+ = 1 - S_{t-1}^-$ .

La prueba de sesgo en el signo se construye a partir de la significación del parámetro  $\phi_1$  en la expresión

$$z_t^2 = \phi_0 + \phi_1 S_{t-1}^- + \eta_t, \quad (2.8)$$

donde  $\eta_t$  es un término de error aleatorio independiente e idénticamente distribuido. Cuando  $\phi_1$  es significativo, existe evidencia suficiente para sostener que las perturbaciones positivas y negativas presentan un impacto diferente en la volatilidad condicional.

Similarmente, la prueba de sesgo en el tamaño se basa en la pendiente indicadora de la ecuación

$$z_t^2 = \phi_0 + \phi_1 S_{t-1}^- \epsilon_{t-1} + \eta_t. \quad (2.9)$$

De esta forma, la significación de  $\phi_1$  sugiere que la magnitud de la perturbación de un signo dado está asociada a la asimetría en la volatilidad. La prueba puede realizarse con las indicadoras de signo negativo o positivo para identificar la dirección de la asimetría, permitiendo diferenciar el efecto del tamaño de una buena noticia destacable respecto de una mala noticia destacable.

Finalmente, es posible probar la existencia conjunta de estos efectos a través de

$$z_t^2 = \phi_0 + \phi_1 S_{t-1}^- + \phi_2 S_{t-1}^- a_{t-1} + \phi_3 S_{t-1}^+ a_{t-1} + \eta_t. \quad (2.10)$$

La prueba emplea como estadístico  $TR^2$ , donde  $T$  es el tamaño de la muestra y  $R^2$  el coeficiente de determinación de la regresión. Bajo la hipótesis nula de simetría con  $\phi_1 = \phi_2 = \phi_3$ , el mismo se distribuye asintóticamente como  $\chi_3^2$ , donde los grados de libertad se corresponden a la cantidad de parámetros autorregresivos.

### 2.1.2. Distribución paramétrica

La forma de la distribución de los retornos difiere para distintas frecuencias de muestreo, a medida que disminuye, los retornos se aproximan más a la distribución gaussiana. En el caso de datos diarios, los trabajos científicos documenta la existencia de asimetría y colas largas en la distribución marginal de los retornos.

Los retornos diarios se muestran leptocúrticos, es decir con picos más apuntalados y colas más pesadas, especialmente cuando se incrementa la frecuencia. Más aún, son condicionalmente de colas pesadas pues parte de este efecto se traslada a los residuos incluso luego de ser filtrados por un modelo de heterocedasticidad condicional. En la práctica, esto implica que la variación en los precios suele fluctuar en un rango más acotado que lo parametrizado por una normal, aunque en algunas ocasiones los retornos saltan hacia valores más extremos. Una parte importante de la curtosis está explicada por los retornos nocturnos, en especial producto de los eventos y anuncios que tienen lugar mientras los mercados están cerrados.

El apalancamiento mencionado anteriormente también afecta la forma de la distribución. Este efecto prevalece en activos de inversión, es decir en aquellos donde los agentes esperan obtener retornos positivos como ser índices, acciones, bonos y algunos *commodities*. Por su parte, las divisas no muestran esta asimetría. El apalancamiento es observado sin importar la forma de medir la volatilidad.

Sin embargo, las características mencionadas no resultan suficientes para identificar la distribución. Por este motivo, la literatura presenta alternativas como la distribución t de Student, hiperbólica, normal inversa, estable y estable

exponencialmente truncada. Para ajustar a las características empíricas de los datos, se debe contar al menos con cuatro parámetros: locación, dispersión, peso en las colas y simetría.

El hecho que los retornos se alejen de la normalidad tiene consecuencias importantes en el área de las finanzas. Muchos métodos desarrollados para la administración de portafolios y la valuación de derivados suponen la distribución gaussiana y fallan severamente en caso contrario. El campo de la administración del riesgo es el más sensible dado que el proceso de modelado está principalmente enfocado en estimar la probabilidad de eventos importantes pero poco frecuentes, como ser una caída abrupta de mercado, o estimar la pérdida dado el peor escenario.

Los encargados de gerenciar el riesgo de una cartera de activos están enfocados principalmente en la cola de la distribución de los retornos, y en su labor diaria se encuentran con dos alternativas que los posicionan en una situación compleja. Por un lado, pueden suponer normalidad, subestimar el riesgo y caer en grandes pérdidas económicas ante la ocurrencia de eventos extremos. Por el otro, pueden recurrir a técnicas no gaussianas que resultan intrínsecamente más complejas y que podrían arrojar resultados incorrectos de ser empleadas de forma inadecuada.

Existen numerosas investigaciones que documentan la subestimación del riesgo que derivaron en pérdidas excesivamente mayores a las esperadas durante la crisis financiera global del año 2007. [Daníelsson \(2011\)](#) cita diversos artículos periodísticos que aluden a este hecho. Agentes de la época mencionan movimientos en los precios equivalentes a 25 veces el desvío estándar ([Larsen, 2007](#)) y eventos modelados con una probabilidad de ocurrencia de una vez cada 10.000 años que finalmente se verificaron durante tres días seguidos ([Whitehouse, 2007](#)).

[Sinclair \(2013\)](#) afirma que la distribución en particular no es importante, siempre que la misma sea fuertemente asimétrica hacia la derecha. Dicho de otra forma, debe modelarse explícitamente que la volatilidad transcurre mucho más tiempo en estados bajos que altos.

El alto grado de variabilidad en los precios implica que los movimientos más bruscos tienen una probabilidad de ocurrencia no despreciable. Las grandes fluc-

tuaciones no pueden ser excluidas ya que forman una fracción importante de los retornos agregados a lo largo de períodos más largos. Estas observaciones motivan a utilizar numerosos modelos teóricos que intentan comprender la naturaleza intermitente de las series de tiempo financieras y replicar de forma adecuada las colas pesadas. La teoría de la administración del riesgo define el Valor en Riesgo (*Value At Risk* - VaR) como el cuantil hacia la derecha de la función de pérdida para un horizonte de tiempo  $j$  dado

$$P \{W(r_j - 1) \leq \text{VaR}(p, j)\} = p, \quad (2.11)$$

donde  $W$  es el valor del portafolio. Las configuraciones más típicas son  $j = 1$  o  $j = 10$  períodos hacia adelante y probabilidades  $p = 0.01$  y  $p = 0.05$ . Esta medida estima la pérdida que podría darse durante un lapso de tiempo dado bajo las condiciones habituales del mercado y se ha convertido en una herramienta fundamental para las regulaciones de requerimiento de capital.

Vale destacar que los valores extremos influyen fuertemente muchos de los estadísticos empleados en la descripción de las series. [Teräsvirta y Zhao \(2011\)](#) emplean estimadores robustos para la curtosis y la autocorrelación a fin de evaluar la capacidad de los diferentes modelos de volatilidad para reproducir los hechos estilizados. Luego de analizar 160 series de retornos logarítmicos diarios para índices bursátiles y tipos de cambio, concluyen que los modelos estudiados que suponen normalidad en la perturbación en la media no logran replicar las colas pesadas incluso cuando la curtosis es medida de manera robusta. En cambio, el efecto de Taylor desaparece.

Por ello, truncar los datos es una práctica muy difundida en aquellas áreas de las finanzas que están dedicadas a describir y modelar el comportamiento medio de los retornos. Por ejemplo, [Poon \(2005\)](#) reporta los resultados luego de aplicar una función *winsoring*<sup>1</sup> para un coeficiente  $\alpha$  dado:

$$\hat{r}_\alpha = \max \left[ \min \left( r, r_{1-\alpha/2} \right), r_{\alpha/2} \right]. \quad (2.12)$$

---

<sup>1</sup>Expresión que lleva el nombre del ingeniero y bioestadístico Charles P. Winsor (1895-1951).



### 2.1.3. Predictibilidad de la volatilidad

Un gran número de trabajos documentan que la volatilidad no es constante (Akgiray, 1989, Turner y Weigel, 1992), hecho que se verifica sin influencia del estimador empleado. Más aún, no sólo varía a lo largo del tiempo, sino que además sigue ciertos patrones, lo cual resulta especialmente importante en términos de predicción. A diferencia de los retornos, que habitualmente se modelan como una serie diferenciada que se comporta como una martingala, la volatilidad muestra persistencia y en consecuencia debería resultar predecible. Estos hechos estilizados no dependen exactamente del activo bajo análisis y son observados para índices, acciones, commodities y monedas.

Como se mencionó anteriormente, la volatilidad está autocorrelacionada y se manifiesta en bloques. Más aún, algunas investigaciones encuentran que el nivel de aglutinación tiende a ser mayor en los mercados desarrollados (Aggarwal *et al.*, 1999). Asimismo, los bloques suelen resultar más pronunciados cuando los precios sufren variaciones negativas, aunque las bajas más pronunciadas presentan caídas más rápidas en la correlación.

Otro hecho que favorece la predicción de la volatilidad es la reversión a la media. Es decir, la correlación decae y eventualmente desaparece, de forma que la volatilidad de corto plazo vuelve hacia la media de largo plazo. Intuitivamente, este hecho es interpretado como la existencia de un cierto nivel estándar hacia el cual la volatilidad eventualmente retorna. Aunque muchos agentes del mercado creen en la reversión a la media, no todos llegan a un acuerdo sobre cuál es el nivel normal y si el mismo es constante a lo largo del tiempo y los cambios institucionales (Engle y Patton, 2001).

En la práctica, esto implica que la variancia en los retornos diarios es mayor respecto de aquella observada para retornos mensuales, lo cual ha sido verificado mediante la prueba de razón de variancias. Se interpreta que los precios fluctúan sin dirigirse puntualmente hacia un determinado nivel en el largo plazo, o bien alternativamente que las perturbaciones sólo tienen efectos transitorios en los precios.

#### 2.1.4. El desafío de los hechos estilizados

Los retornos suelen mostrar baja autocorrelación lineal pero alta dependencia no lineal. Algunas transformaciones ponen en evidencia la dependencia, la cual se maximiza cuando se analiza la función de autocorrelación del valor absoluto. El efecto apalancamiento es otra forma de dependencia no lineal. Su existencia puede verificarse mediante las pruebas de sesgo en el signo y en el tamaño. Como se mencionó, la distribución de los retornos depende de la frecuencia de muestreo: a mayor frecuencia, mejor aproximación a la distribución gaussiana. Las series diarias documentan asimetría, leptocurtosis y presencia de valores extremos. La volatilidad de los retornos, por su parte, se manifiesta en bloques y presenta reversión a la media.

Todos estos hechos estilizados son ampliamente tratados en la literatura financiera. A pesar de haber sido profundamente descritos, aún se presentan grandes desafíos a la hora de modelar los retornos y la volatilidad. Por un lado, existen numerosas formas de especificar cada característica observada. Por el otro, en muchas oportunidades el investigador se encuentra obligado a priorizar alguno de los fenómenos, en especial dado que incluir todos ellos generaría un modelo fuertemente parametrizado con problemas de especificación. Por último, no resulta evidente que capturar efectos significativos arroje mejoras en las predicciones fuera de la muestra.

## 2.2. Volatilidad

La volatilidad es un concepto central en las finanzas, en especial para las teorías de valuación de activos, selección de portafolios y administración del riesgo. Como tal, existen diferentes líneas de investigación dedicadas a tratar los problemas de medición, modelado y pronóstico.

En términos generales representa una medida de la variabilidad en el precio de un activo para un período de tiempo dado, admite diferentes definiciones en función del contexto donde se emplea. Es común asociar el término volatilidad con un parámetro que describe el desvío estándar de los retornos  $\sigma$ , sean porcentuales o logarítmicos. En este último caso, bajo el tradicional supuesto que

los precios siguen un movimiento geométrico browniano, el desvío estándar para un período de duración  $T$  equivale a  $\sigma\sqrt{T}$ .

Los analistas financieros suelen hacer referencia al término volatilidad histórica cuando analizan el comportamiento histórico de una serie de precios. Como se verá más adelante, esto representa un problema de estimación. Los econométricos, por su parte, definen la volatilidad condicional como el desvío estándar de un retorno futuro que está condicionado a un conjunto de información disponible a un momento dado. El valor esperado de la volatilidad para el período siguiente es calculado a partir de un modelo de series de tiempo, cuyos parámetros a su vez son estimados en función de información histórica. Algunos modelos suponen que la variancia de un proceso estocástico es una variable aleatoria que tiene su propia variancia, concepto denominado volatilidad estocástica. Por último, la teoría de valuación de activos derivados define la volatilidad implícita como el valor estimado a partir del precio de mercado que tiene una opción. En este contexto, la volatilidad equivale al parámetro  $\sigma$  que igualan el valor teórico del contrato según un modelo matemático dado y el valor negociado en el mercado.

En todos los casos, las definiciones responden a diferentes problemas del conocimiento científico. Por lo tanto, a partir de un mismo conjunto de datos, las estimaciones realizadas difieren en función de cada modelo subyacente y los supuestos empleados.

Es un hecho ampliamente aceptado que la volatilidad no es constante, sino que está sujeta a fluctuaciones a lo largo del tiempo. Esto no sólo responde a los estudios realizados por la comunidad científica, sino además al consenso de los agentes y practicantes de los mercados. A pesar de ello, [Taylor \(2005\)](#) expresa que no existe una explicación completa y satisfactoria sobre la causa en los movimientos de la volatilidad.

El autor releva una considerable cantidad de respuestas parciales, pero reconoce que gran parte de la variación queda aún sin explicar. Por ejemplo, la volatilidad del mercado se incrementa en momentos de crisis económicas y disminuye en situaciones de estabilidad. Asimismo, eventos políticos pueden servir de disparadores que alimentan la variabilidad. Por otro lado, variables macroeconómicas fundamentales como la inflación, el empleo y la producción tienen su

impacto en la volatilidad de las acciones, el tipo de cambio y las tasas de interés. El nivel del mercado también afecta la volatilidad, en especial al considerar el efecto apalancamiento descrito en la [Sección 2.1.1](#). Diferentes teorías de valuación de activos intentan explicar parte de los cambios en el nivel volatilidad. Por ejemplo, dado que la decisión de negociar un título está asociada a la llegada de nueva información al mercado, algunos autores han propuesto modelos que exploran la relación entre la cantidad de noticias y la volatilidad observada.

Antes de conformar un modelo predictivo, es necesario encontrar una forma de medir la volatilidad efectivamente verificada en el pasado. Esta tarea no es tan sencilla como medir un precio pues la volatilidad no es observable instantáneamente sino que requiere del paso del tiempo para manifestarse. Al tratarse de una variable no observable de forma directa, un importante número de autores han diseñado un amplio menú de estimadores estadísticos cuyas ventajas y desventajas suelen ser primariamente analizadas desde dos puntos de vista: el sesgo y la eficiencia.

El sesgo estudia si el estimador arroja resultados que se encuentran sistemáticamente debajo o encima del verdadero valor. Esta propiedad depende de varios factores como ser la distribución del proceso subyacente, el tamaño de la muestra, los cambios en la volatilidad, la existencia de desplazamientos y la correlación entre la volatilidad diaria y nocturna. Por su parte, la eficiencia se reduce al análisis de la velocidad de convergencia del estimador al verdadero valor. En el caso de los estimadores más complejos que se presentan a continuación, la eficiencia se calcula en forma relativa a la variancia del estimador del desvío estándar.

Para una mayor simplificación, la secuencia de precios se supone homogénea. [Sinclair \(2013\)](#) discute los ajustes necesarios que deben aplicarse en el precio de una acción para evitar que el pago de dividendos afecte incorrectamente la estimación de la volatilidad.

### **2.2.1. Estimador de cierre a cierre**

Conceptualmente, la volatilidad es la suma de infinitos retornos instantáneos tomados en períodos infinitesimales y no solapados que componen una unidad

de tiempo. En tiempo discreto, se traduce en la raíz cuadrada de la variancia de los retornos logarítmicos

$$\hat{\sigma}^2 = \frac{1}{T} \sum_{t=1}^T (r_t - \bar{r})^2, \quad (2.13)$$

$$\hat{\sigma} = \sqrt{\hat{\sigma}^2}, \quad (2.14)$$

donde  $T$  es el tamaño de la muestra. El estimador puede ser reexpresado para un horizonte de tiempo diferente al tamaño de la muestra, para lo cual se emplea un factor equivalente a la raíz cuadrada de la cantidad de períodos con negociación que conforman el horizonte temporal deseado. Por ejemplo, partiendo de retornos logarítmicos diarios, la volatilidad anualizada equivale a  $\hat{\sigma} \times \sqrt{252}$  suponiendo 252 días de negociación al año.

La [Ecuación \(2.13\)](#) sólo requiere convergencia en la suma y no realiza supuestos sobre la distribución del proceso generador de los retornos logarítmicos. En los procesos financieros resulta difícil diferenciar la media, llamada desplazamiento o *drift*, de la variancia de los retornos. Además, los estimadores para los retornos medios habitualmente tienen un gran componente de ruido, en especial para muestras de tamaño pequeño. Por ello, habitualmente se fija el retorno medio en cero a fin de eliminar una fuente de ruido e incrementar la precisión de la medición

$$\hat{\sigma}^2 = \frac{1}{T} \sum_{t=1}^T (r_t)^2, \quad (2.15)$$

esto equivale a suponer que el desplazamiento es nulo. Por su parte, la [Ecuación \(2.13\)](#) y la [Ecuación \(2.15\)](#) suponen que la media es conocida, por lo cual es necesario ajustar los grados de libertad a fin de estimar la variancia poblacional a partir de datos muestrales

$$\hat{\sigma}_{cc}^2 = \frac{T}{T-1} \hat{\sigma}^2. \quad (2.16)$$

Las propiedades pueden encontrarse en [Casella y Berger \(2002\)](#), en especial:

$$E \langle \hat{\sigma}_{cc}^2 \rangle = \sigma^2 \quad (2.17)$$

y

$$V \langle \hat{\sigma}_{cc}^2 \rangle = \frac{2\sigma^2}{T}. \quad (2.18)$$

Si bien la [Ecuación \(2.16\)](#) conforma un estimador insesgado para la variancia, su raíz cuadrada subestima el desvío estándar. Consecuencia de la desigualdad de Jensen, que establece que la transformación convexa de la media es siempre menor o igual a la media del valor transformado, se obtiene

$$E \langle \hat{\sigma} \rangle = E \langle \sqrt{\hat{\sigma}^2} \rangle \leq \sqrt{E \langle \hat{\sigma}^2 \rangle} = \sqrt{\sigma^2} = \sigma. \quad (2.19)$$

Si se supone que el proceso generador de los retornos es gaussiano, es posible derivar la distribución muestral del estimador del desvío estándar para una muestra de tamaño  $T$  ([Kenney y Keeping, 1951](#))

$$f(\hat{\sigma}_{cc}) = 2 \frac{\left(\frac{T}{2\sigma^2}\right)^{\frac{T-1}{2}}}{\Gamma\left(\frac{T-1}{2}\right)} \exp\left\{-\frac{T\hat{\sigma}_{cc}}{2\sigma^2}\right\} \hat{\sigma}_{cc}^{T-2}, \quad (2.20)$$

donde el estimador del desvío estándar es  $\hat{\sigma}_{cc} = \sqrt{\hat{\sigma}_{cc}^2}$ . El valor esperado es ([Kenney y Keeping, 1951](#), p. 135, ec. 28)

$$E \langle \hat{\sigma}_{cc} \rangle = \sqrt{\frac{2}{T}} \frac{\Gamma\left(\frac{T}{2}\right)}{\Gamma\left(\frac{T-1}{2}\right)} \sigma, \quad (2.21)$$

y el sesgo puede ser corregido mediante la expresión

$$\frac{\hat{\sigma}_{cc}}{b(T)} \quad (2.22)$$

con

$$b(T) = \sqrt{\frac{2}{T}} \frac{\Gamma\left(\frac{T}{2}\right)}{\Gamma\left(\frac{T-1}{2}\right)}. \quad (2.23)$$

Empleando la siguiente aproximación

$$\frac{\Gamma\left(k + \frac{1}{2}\right)}{\Gamma(k)} = \sqrt{k} \left(1 - \frac{1}{8k} + \frac{1}{128k} + \dots\right), \quad (2.24)$$

entonces se puede lograr una aproximación de primer orden para  $b(T)$

$$b(T) \approx \sqrt{1 - \frac{3}{2T}}. \quad (2.25)$$

Por su parte, la variancia del estimador es

$$V \langle \hat{\sigma}_{cc} \rangle = \frac{1}{T} \left( T - 1 - \frac{2\Gamma^2 \left( \frac{T}{2} \right)}{\Gamma^2 \left( \frac{T-1}{2} \right)} \right) \sigma^2 = \frac{1}{T} (T - 1 - \sqrt{T}b^2) \sigma^2 \approx \frac{\sigma^2}{2T}. \quad (2.26)$$

De esta aproximación surge una regla habitualmente expresada de la siguiente forma: el error estándar del desvío estándar es  $2^{-\frac{1}{2}}$  veces el error estándar de la media.

La aproximación presentada muestra que el estimador es ineficiente, es decir que converge lentamente al verdadero valor de la volatilidad. En la práctica, esto significa que el intervalo de confianza para la volatilidad histórica depende del tamaño de la muestra, hecho que resulta aceptable en otros contextos donde el proceso subyacente es estable a lo largo del tiempo. El intervalo viene dado por

$$IC_{1-\alpha}(\sigma) \approx \left( \hat{\sigma}_{cc} - z_{1-0.5\alpha} \frac{\hat{\sigma}_{cc}}{\sqrt{2T}}, \hat{\sigma}_{cc} + z_{1-0.5\alpha} \frac{\hat{\sigma}_{cc}}{\sqrt{2T}} \right), \quad (2.27)$$

donde  $1 - \alpha$  es el coeficiente de confianza y  $z_p$  es el valor de la variable normal estándar que acumula la probabilidad  $p$ .

En los mercados financieros se presenta un inconveniente: por un lado, emplear pocos datos da lugar a estimaciones con mucho ruido producto del error de muestreo, mientras que incrementar el número de observaciones ampliando el ancho de la ventana implica incorporar al modelo información que posiblemente ya no resulte relevante para el estado del mercado vigente al momento de la estimación. El punto justo entre ambos extremos depende del contexto de la investigación y el analista financiero. Cuando se trabaja con retornos diarios, es práctica habitual emplear un tamaño de muestra de  $T = 22$  equivalente a la cantidad de días de negociación por mes. En tal caso, el intervalo de confianza del 95 % es tan amplio como

$$100 \times \frac{z_{1-\alpha} \sigma / \sqrt{2T}}{\sigma} = 100 \times \frac{1.96}{\sqrt{44}} \approx 29.55 \quad (2.28)$$

por ciento de la verdadera volatilidad.

En el caso de la volatilidad, el error muestral no está asociado a errores de medición. Ignorando las diferencias entre las partes compradora y vendedora, el precio de un activo es un número exacto y, por lo tanto, la volatilidad también

lo es. Aun así, el hecho de no ser directamente observable origina incertidumbre si la medida que se emplea es verdaderamente representativa de la realidad subyacente.

Tradicionalmente se han presentado dos enfoques para solucionar el gran error de muestreo observado en las series de precios. El primero implica incrementar la frecuencia de muestreo y sumar el cuadrado del retorno para intervalos intradiarios, lo cual requiere el acceso a datos de alta frecuencia. El segundo consiste en crear estimadores que incorporen mayor información que el retorno y, en consecuencia, presentan la desventaja de necesitar datos adicionales. Cada enfoque presenta sus limitaciones, pero es posible conjugarlos diseñando estimadores mejorados que luego se aplican en intervalos intradiarios. El manejo de datos de alta frecuencia excede el alcance del presente trabajo, motivo por el cual la sección siguiente hace foco en aquellos basados en información aumentada.

### 2.2.2. Estimador de Parkinson

Parkinson (1980) toma herramientas de la física para modelar el cambio en los precios como el movimiento de una partícula. Intuitivamente, el autor sostiene que la diferencia entre los valores mínimo y máximo que un precio toma en un intervalo de tiempo dado arroja un buen estimador de la variancia, en especial dado que esta diferencia tiende a ser menor o mayor cuando la constante de difusión también lo es. Formalmente, emplea la función de error de Gauss y la función de error complementaria para estimar la variancia de los retornos mediante los valores extremos.

Sean  $h_t$  y  $l_t$  los valores máximo y mínimo que un precio toma dentro de un intervalo de tiempo dado  $t$ . El autor propone estimar la constante de difusión  $\sigma^2$  mediante la suma de distancias

$$\hat{\sigma}_{park}^2 = \frac{1}{4T \ln 2} \sum_{t=1}^T \left( \ln \frac{h_t}{l_t} \right)^2, \quad (2.29)$$

de forma que el estimador para el desvío estándar del retorno logarítmico es

$$\hat{\sigma}_{park} = \sqrt{\hat{\sigma}_{park}^2}. \quad (2.30)$$



El estimador de la variancia es insesgado si los precios son continuos. Sin embargo, los precios son registrados de forma discreta, no sólo porque la negociación se realiza en unidades discretas sino especialmente porque el mercado sólo está abierto durante parte del día. Es decir, los verdaderos precios mínimos o máximos de un activo pueden negociarse fuera del horario de mercado y no ser registrados. Como consecuencia de estos motivos, el estimador subestima sistemáticamente la variancia en función del tamaño de la muestra, sesgo cuantificado por [Garman y Klass \(1980, Tabla 1\)](#) mediante técnicas de simulación. Aunque estos valores pueden ser utilizados como un factor de corrección, no solucionan el hecho de que el estimador de Parkinson no considera los saltos existentes en la apertura. Además, incluso cuando la corrección elimina el sesgo en la variancia, el estimador del desvío estándar presentado en la [Ecuación \(2.30\)](#) continúa siendo sesgado por la desigualdad de Jensen.

Como punto positivo al momento de trabajar en aplicaciones con datos reales, [Brandt y Diebold \(2003\)](#) destacan que los estimadores basados en distancias son robustos a los ruidos generados por la microestructura de los mercados, como ser las diferencias en las partes compradora y vendedora y el rebote que se observa entre ellas.

La variancia del estimador puede obtenerse por definición

$$V \langle \hat{\sigma}_{park}^2 \rangle = E \langle (\hat{\sigma}_{park}^2 - \sigma^2)^2 \rangle = \left[ \frac{E \langle L^4 \rangle}{E \langle L^2 \rangle} - 1 \right] \frac{\sigma^2}{T} \approx \frac{0.41\sigma^2}{T}, \quad (2.31)$$

donde  $L_t = h_t - l_t$  es la diferencia entre el mayor y el menor precio en el  $i$ -ésimo período de tiempo. La manera de encontrar el valor esperado de  $E \langle L^p \rangle$  para  $p \in \mathbb{R} \geq 1$  está asociada a las propiedades de la función de error de Gauss y es explicada por el autor en su artículo original. La eficiencia relativa de este estimador respecto del estimador de cierre a cierre, cuya variancia surge de la [Ecuación \(2.18\)](#), puede estudiarse a través de la razón

$$\frac{V \langle \hat{\sigma}_{park}^2 \rangle}{V \langle \hat{\sigma}_{cc}^2 \rangle} \approx \frac{0.41\sigma^2}{T} \frac{T}{2\sigma^2} \approx 0.205 \quad (2.32)$$

y concluir que este estimador de distancias es aproximadamente cinco veces más eficiente que la variancia muestral de los retornos logarítmicos. Intuitivamente, el primer estimador converge más rápidamente al verdadero valor de la volatilidad

porque emplea la información proveniente de dos precios para cada período de tiempo, mientras que el segundo sólo utiliza uno. De esta forma, el analista financiero obtiene una estimación cinco veces más precisa para un tamaño de muestra dado, o bien puede optar por trabajar con la misma variabilidad y emplear sólo el 20 % de los datos más actuales, los cuales posiblemente sean más representativos del estado del mercado vigente al momento de la investigación.

### 2.2.3. Estimador de Garman-Klass

Garman y Klass (1980) parte de las limitaciones de los estimadores estudiados hasta entonces y proponen uno nuevo que incorpora otros datos financieros fácilmente accesibles para el público en general, por ejemplo a través de periódicos. Intuitivamente, es sencillo ver que los precios mínimo y máximo son aquellos que agregan el mayor cúmulo de información pues resumen todos los datos que conforman una unidad de tiempo. No obstante, los autores sostienen que los valores de apertura y cierre pueden aportar una mejora marginal a la estimación.

Suponiendo que los precios se negocian continuamente y conforman un movimiento browniano geométrico sin desplazamientos, el estimador está dado por

$$\hat{\sigma}_{gk} = \sqrt{\frac{1}{T} \left[ \frac{1}{2} \sum_{t=1}^T \left( \ln \frac{h_t}{l_t} \right)^2 - \sum_{t=1}^T (2 \ln 2 - 1) \left( \ln \frac{c_t}{o_t} \right)^2 \right]}, \quad (2.33)$$

donde  $o_t$  y  $c_t$  son los precios de apertura y cierre para el  $t$ -ésimo período de tiempo. El mismo se constituye en el estimador insesgado de menor variancia cuando el proceso subyacente en tiempo continuo no tiene desplazamiento. Sin embargo, estudios de simulación muestran que su variancia es aproximadamente ocho veces más pequeña respecto del estimador de cierre a cierre, la eficiencia es muy sensible a los supuestos sobre el proceso generador de datos.

Tal como se estudió anteriormente, subestima el verdadero valor de la variancia debido al muestreo en tiempo discreto. En especial, la Ecuación (2.33) emplea valores sólo para el  $t$ -ésimo período, es decir no captura saltos de precios entre el cierre en un período dado y la apertura en el siguiente. El sesgo podría ser corregido a través de un factor.

### 2.2.4. Estimador de Rogers-Satchell

Rogers y Satchell (1991) continúan el desarrollo de Garman-Klass y logran su generalización para cualquier valor del desplazamiento. El nuevo estimador está dado por

$$\hat{\sigma}_{rs} = \sqrt{\frac{1}{T} \sum_{t=1}^T \left[ \left( \ln \frac{h_t}{c_t} \right) \left( \ln \frac{h_t}{o_t} \right) + \left( \ln \frac{l_t}{c_t} \right) \left( \ln \frac{l_t}{o_t} \right) \right]}, \quad (2.34)$$

el cual es insesgado para cualquier valor del parámetro de desplazamiento. Dado que el estimador de Garman-Klass es el más eficiente entre los insesgados cuando el desplazamiento es nulo,  $\hat{\sigma}_{rs}$  sólo ofrece un mejor rendimiento cuando este parámetro es efectivamente distinto de cero. Más adelante, Rogers *et al.* (1994) presentan una corrección para ajustar el sesgo hacia abajo causado por el muestreo en tiempo discreto.

### 2.2.5. Estimador de Yang-Zhang

Yang y Zhang (2000) diseñan un estimador insesgado para tiempo continuo y de mayor eficiencia que admite la existencia de desplazamientos y saltos.

El estimador se construye como un promedio ponderado entre los estimadores de apertura a cierre, cierre a cierre y Rogers-Satchell-Yoon,

$$\hat{\sigma}_{yz} = \sqrt{\hat{\sigma}_o^2 + k\hat{\sigma}_c^2 + (1-k)\hat{\sigma}_{rs}^2}, \quad (2.35)$$

donde

$$\hat{\sigma}_o^2 = \frac{1}{T-1} \sum_{t=1}^T \left( \ln \left( \frac{o_t}{o_{t-1}} \right) - \frac{1}{T} \sum_{j=1}^T \ln \left( \frac{o_j}{o_{j-1}} \right) \right)^2, \quad (2.36)$$

$$\hat{\sigma}_c^2 = \frac{1}{T-1} \sum_{t=1}^T \left( \ln \left( \frac{c_t}{c_{t-1}} \right) - \frac{1}{T} \sum_{j=1}^T \ln \left( \frac{c_j}{c_{j-1}} \right) \right)^2, \quad (2.37)$$

$$k = \frac{0.34}{1.34 + \frac{T+1}{T-1}}. \quad (2.38)$$

La constante  $k$  surge de una optimización cuadrática que minimiza la variancia del estimador, aunque las propiedades mencionadas son independientes del valor seleccionado.

Es insesgado en tiempo continuo independientemente de la magnitud del desplazamiento y los saltos. Supone que no existe correlación entre la volatilidad diaria y nocturna, cayendo en problemas de subestimación en caso contrario.

La eficiencia depende tanto del tamaño de la muestra como de la magnitud de los saltos observados en el conjunto de datos. Cuando no existen saltos, el mismo alcanza una eficiencia relativa máxima equivalente a 14 veces la variancia del estimador de cierre a cierre. Por otro lado, las variancias de ambos estimadores se equiparan cuando los saltos dominan. Nuevamente, el estimador de Garman-Klass es aquél de menor variancia cuando no existe desplazamiento, por lo tanto Yang-Zhang cede cierta eficiencia para lograr independencia respecto de este parámetro. La pérdida de precisión es inversa al tamaño de la muestra.

### 2.2.6. Elección del estimador

Si bien la literatura ofrece muchas más variantes, se seleccionaron cinco estimadores entre los más empleados. Cada uno de ellos se construye en función de diversos supuestos, y en muchas oportunidades nacen como respuesta a las debilidades de otros estimadores establecidos previamente.

Estimador	Datos	Desplazamiento	Saltos	Eficiencia máxima
Cierre a cierre	Cierre	No	No	1.0
Parkinson	Máximo y mínimo	No	No	5.2
Garman-Klass	Apertura, máximo, mínimo y cierre	No	No	7.4
Rogers-Satchell	Apertura, máximo, mínimo y cierre	Sí	No	8.0
Yang-Zhang	Apertura, máximo, mínimo y cierre, apertura y cierre del período anterior	Sí	Sí	14.0

**Cuadro 2.1:** Resumen de los estimadores seleccionados para la volatilidad en los retornos de una acción.

Las propiedades teóricas y las simulaciones basadas en el movimiento geométrico browniano parecen concluir que los estimadores más complejos ofrecen una mejora sustancial en términos de eficiencia. No obstante, [Brandt y Kinlay \(2005\)](#) encuentran que los beneficios son muy sensibles a las características del proceso subyacente. Los autores ponen a prueba los estimadores ante fallas en los supuestos para evaluar el impacto del tamaño de la muestra, la frecuencia de los datos, el valor del parámetro de desplazamiento, la magnitud de los saltos

en la apertura del mercado y cambios en la volatilidad a lo largo del tiempo. Encuentran que los estimadores de alta frecuencia son los mejores en términos de sesgo y eficiencia, mientras que los presentados en el [Cuadro 2.1](#) están sesgados producto del muestreo en tiempo discreto además de ser muy vulnerables a violaciones de otros supuestos.

Fuera de las simulaciones, los autores aplican los estimadores a valores históricos del índice S&P500. Dado que la volatilidad no es observable, emplean un estimador de alta frecuencia para intervalos de cinco minutos como punto de referencia. Encuentran que ninguno de aquellos mencionados en esta sección alcanza la eficiencia teórica, siendo el estimador de cierre a cierre el más pobre y Parkinson el más preciso. Sorpresivamente, con marcada diferencia respecto de lo sucedido en las simulaciones, los estimadores aplicados a datos reales presentan correlaciones entre 0.911 y 0.999. Esta discrepancia los hace concluir sobre la existencia de características fundamentales en el comportamiento de mercado que no son capturadas por las simulaciones.

# Capítulo 3

## Modelos de heterocedasticidad condicional

### 3.1. Modelos para la volatilidad

Se supone que el retorno logarítmico sigue un modelo simple para series de tiempo como ser un proceso estacionario autoregresivo de media móvil  $ARMA(p, q)$  con variables explicativas

$$r_t = \mu_t + a_t, \quad (3.1)$$

y

$$\mu_t = \sum_{i=1}^p \phi_i \left( r_{t-i} - \phi_0 - \sum_{j=1}^k \beta_j x_{j,t-i} \right) - \sum_{i=1}^q \theta_i a_{t-i}, \quad (3.2)$$

donde  $k$  es la cantidad de covariables,  $p$  es el orden del proceso autoregresivo,  $q$  es el orden del proceso de media móvil, todos ellos enteros no negativos, y finalmente  $x_j$  son covariables. Al combinarse con la [Ecuación \(2.2\)](#), la variancia condicional es

$$\sigma_t^2 = V_{t-1} \langle r_t \rangle = V_{t-1} \langle a_t \rangle. \quad (3.3)$$

El modelo para  $\mu_t$  de la [Ecuación \(3.2\)](#) es la ecuación para la media de los retornos, mientras que el modelo para  $\sigma_t^2$  de la [Ecuación \(3.3\)](#) es la ecuación para la volatilidad de los retornos. El término  $a_t$  se corresponde con el residuo de la ecuación para la media, y en el ámbito de la econometría es habitualmente llamado perturbación, innovación o shock en el retorno de un activo al momento

$t$ . Por su parte, el desvío estándar condicional  $\sigma_t$  corresponde a la raíz positiva de la variancia condicional  $\sigma_t^2$ .

Los modelos para la volatilidad se distinguen por la forma en que  $\sigma_t^2$  evoluciona a través del tiempo. Los modelos de heterocedasticidad condicional pueden ser agrupados en dos categorías según la función que emplean para describir la volatilidad: aquellos que usan una función determinística como los GARCH y aquellos que incluyen una fuente de error aleatorio como los modelos de volatilidad estocástica.

### 3.1.1. Modelo ARCH

Engle (1982) propuso el primer acercamiento que provee un conjunto sistemático de herramientas para modelar la volatilidad. Aunque las perturbaciones  $a_t$  no están autocorrelacionadas, muestran una forma de dependencia que puede ser descripta mediante una simple función cuadrática de los valores rezagados.

El modelo autoregresivo con heterocedasticidad condicional de orden  $m$   $ARCH(m)$  descompone la perturbación en dos términos

$$a_t = \sqrt{h_t} \epsilon_t, \quad (3.4)$$

donde  $\epsilon_t$  es una secuencia de variables aleatorias independientes e idénticamente distribuidas con  $E \langle \epsilon_t \rangle = 0$  y  $V \langle \epsilon_t \rangle = 1$ . Por su parte, la dinámica de la variancia condicional está dada por

$$h_t = \alpha_0 + \sum_{i=1}^m \alpha_i a_{t-i}^2, \quad (3.5)$$

con  $\alpha_0 > 0$  y  $\alpha_i \geq 0 \forall i > 0$ . Los coeficientes  $\alpha_i$  deben respetar ciertas condiciones de regularidad para garantizar que la variancia marginal de las perturbaciones  $V \langle a_t \rangle$  sea finita. El lector puede encontrar mayores detalles en Hamilton (1994) y Tsay (2010).

Este modelo logra reproducir parte de los hechos estilizados. Por ejemplo, grandes perturbaciones pasadas implican una variancia condicional mayor para futuras perturbaciones. Por su parte, las colas de los shocks son pesadas pues el exceso de curtosis marginal es positivo incluso cuando  $\epsilon_t$  sigue una distribución

gaussiana, aunque no lo suficiente para reproducir lo observado empíricamente. No obstante, tiene sus limitaciones. Restringir el modelo para que tenga un cuarto momento finito impone cotas rígidas a los posibles valores de los parámetros. Además, la reacción de la volatilidad a la perturbación es simétrica, y se observa que el modelo muestra cierta lentitud a la hora de responder a perturbaciones de magnitud cuando se dan de forma aislada.

### 3.1.2. Modelo GARCH

El modelo ARCH es simple y habitualmente requiere un orden  $m$  elevado para replicar el proceso de la volatilidad. En consecuencia, de forma independiente [Bollerslev \(1986\)](#) y [Taylor \(1986\)](#) proponen una extensión conocida como modelo autoregresivo con heterocedasticidad condicional generalizado.

El modelo  $GARCH(m, s)$  descompone la perturbación nuevamente en dos términos

$$a_t = \sqrt{h_t} \epsilon_t, \quad (3.6)$$

donde  $\epsilon_t$  es una secuencia de variables aleatorias independientes e idénticamente distribuidas con  $E \langle \epsilon_t \rangle = 0$  y  $V \langle \epsilon_t \rangle = 1$ . Por su parte, la dinámica de la volatilidad condicional está dada por

$$h_t = \alpha_0 + \sum_{i=1}^m \alpha_i a_{t-i}^2 + \sum_{j=1}^s \beta_j h_{t-j}, \quad (3.7)$$

con  $\alpha_0 > 0$ ,  $\alpha_i \geq 0 \forall i > 0$ ,  $\beta_j \geq 0 \forall j$  y  $\sum_{i=1}^{\max(m,s)} \alpha_i + \beta_i < 1$  con  $\alpha_i = 0 \forall i > m$  y  $\beta_i = 0 \forall i > s$ . Esta última restricción permite que la variancia marginal de la perturbación  $V \langle a_t \rangle$  resulte finita. El modelo es un caso especial de la familia  $ARCH(m)$  para  $m = \infty$  y se reduce a  $ARCH(m)$  cuando  $s = 0$ . Asimismo, puede ser reescrito como un ARMA para la serie del cuadrado de las perturbaciones al definir  $\eta_t = a_t^2 - h_t$  y reemplazar  $h_t$  en la [Ecuación \(3.7\)](#).

La variancia condicional definida en la [Ecuación \(3.7\)](#) permite que la función de autocorrelación del cuadrado de la perturbación, si existe, decaiga lenta y exponencialmente. La forma ARCH muestra una tasa de disminución muy rápida respecto de lo observado en las series de tiempo financieras, salvo que el rezago máximo  $m$  sea muy grande, de manera que su generalización se presenta como



una alternativa más parsimoniosa. Nuevamente, este modelo replica los bloques de volatilidad, el exceso de curtosis y además provee una función determinística simple que describe la evolución de la volatilidad. Al igual que la parametrización ARCH, la respuesta de la volatilidad a los shocks es simétrica y el exceso de curtosis cuando  $\epsilon_t$  sigue una distribución gaussiana no refleja la leptocurtosis observada empíricamente.

### 3.1.3. Modelo EGARCH

A fin de resolver algunas de estas debilidades, [Nelson \(1991\)](#) propone una extensión llamada GARCH Exponencial o EGARCH. La ecuación de volatilidad está dada por

$$\log h_t = \alpha_0 + \sum_{i=1}^m \alpha_i \frac{|a_{t-i}| + \gamma_i a_{t-i}}{\sqrt{h_{t-i}}} + \sum_{j=1}^s \beta_j \log h_{t-j}. \quad (3.8)$$

Esta representación emplea el logaritmo natural de la variancia condicional para flexibilizar las restricciones impuestas a los coeficientes del modelo GARCH a fin de garantizar valores positivos. Además, el uso de una función no lineal permite que el modelo responda en forma distinta según el signo de las perturbaciones rezagadas. El efecto autoregresivo en la volatilidad es

$$\begin{cases} \exp\left(\alpha_i(1 + \gamma_i)a_{t-i}h_{t-i}^{-0.5}\right) & \text{cuando } a_{t-i} \geq 0 \\ \exp\left(\alpha_i(1 - \gamma_i)a_{t-i}h_{t-i}^{-0.5}\right) & \text{cuando } a_{t-i} < 0. \end{cases} \quad (3.9)$$

El parámetro  $\gamma_i$  captura el efecto apalancamiento. En función de los hechos estilizados estudiados se espera que  $\gamma_i < 0$ , de forma que las malas noticias incrementen la volatilidad.

### 3.1.4. Modelo GJRARCH

Una forma alternativa de capturar el efecto apalancamiento es mediante el modelo GJRARCH, nombrado a partir de sus autores ([Glosten \*et al.\*, 1993](#)). La ecuación de volatilidad está dada por

$$h_t = \alpha_0 + \sum_{i=1}^m (\alpha_i + \gamma_i S_{t-i}^-) a_{t-i}^2 + \sum_{j=1}^s \beta_j h_{t-j}, \quad (3.10)$$

donde se incorpora una variable indicadora del signo negativo para la perturbación del período anterior  $S_{t-1}^- = \mathbb{I}_{(a_{t-1} < 0)}$ . Los parámetros deben cumplir ciertas condiciones de no negatividad similares a las mencionadas para el modelo GARCH.

El uso de la variable indicadora permite responder de forma distinta según el signo de las perturbaciones rezagadas. El efecto autoregresivo en la volatilidad es

$$\begin{cases} \alpha_i a_{t-i}^2 & \text{cuando } a_{t-i} \geq 0 \\ (\alpha_i + \gamma_i) a_{t-i}^2 & \text{cuando } a_{t-i} < 0. \end{cases} \quad (3.11)$$

El modelo fija un umbral en cero para diferenciar el impacto de las perturbaciones pasadas. El parámetro  $\gamma_i$  captura el efecto apalancamiento, donde  $\gamma_i > 0$  implica que un shock negativo tiene un efecto mayor respecto del shock positivo.

### 3.1.5. Modelo TGARCH

[Zakoian \(1994\)](#) propone un modelo que funciona de forma muy similar a GJRARCH, aunque especifica el desvío estándar condicional en lugar de la variancia condicional. La ecuación del desvío estándar condicional está dada por

$$\sqrt{h_t} = \alpha_0 + \sum_{i=1}^m (\alpha_i + \gamma_i S_{t-i}^-) |a_{t-i}| + \sum_{j=1}^s \beta_j \sqrt{h_{t-j}}. \quad (3.12)$$

### 3.1.6. Modelo NGARCH

[Higgins y Bera \(1992\)](#) proponen una familia de modelos que capturan efectos no lineales en la heterocedasticidad condicional. La ecuación de volatilidad está dada por

$$h_t^\delta = \alpha_0 (\sigma^2)^\delta + \sum_{i=1}^m \alpha_i (a_{t-i}^2)^\delta, \quad (3.13)$$

donde  $\sigma^2 > 0$ ,  $\alpha_i \geq 0 \forall i$ ,  $\sum_{i=1}^m \alpha_i = 1$  y  $\delta > 0$ .

El parámetro  $\delta$  funciona como un parámetro para la transformación de potencias de Box-Cox ([Box y Cox, 1964](#)) y tiene como objetivo linealizar relaciones no lineales. Este modelo cuenta con  $m + 3$  parámetros pero incorpora la restricción en la suma de los coeficientes  $\alpha_i$ , de forma que efectivamente tiene sólo un parámetro adicional al  $ARCH(m)$ . Los mismos son equivalentes cuando  $\delta = 1$ .

### 3.1.7. La curva de impacto de noticias

En muchas oportunidades se observa que los períodos de gran volatilidad se inician con retornos negativos de gran magnitud, efecto que motiva el uso de las variantes presentadas. La curva de impacto de noticias (*news impact curve* - NIC) introducida por [Pagan y Schwert \(1990\)](#) y popularizada por [Engle y Ng \(1993\)](#) ofrece una forma de comparar el ajuste entre ellos.

Esta curva relaciona la perturbación en la media para un momento dado  $a_t$  y la volatilidad condicional del período siguiente  $h_{t+1}$  manteniendo constante el conjunto de información. En el caso de la especificación  $GARCH(1, 1)$ , la relación está dada por

$$NIC(a_t) = \alpha + \alpha_1 a_t^2 + \beta_1 h_t, \quad (3.14)$$

donde la única información del pasado relevante es la variancia condicional del período  $t$ . Esta curva toma una función cuadrática centrada en  $a_t = 0$ . La variancia condicional genera desplazamientos verticales pero no modifica su forma.

El modelo  $EGARCH(1, 1)$ , siguiendo la [Ecuación \(3.8\)](#), construye una curva asimétrica gobernada por la forma

$$NIC(a_t) = \begin{cases} h_t^{\beta_1} \exp\left(\alpha_0 - \gamma_1 \sqrt{2/\pi}\right) \exp\left(\frac{\alpha_1 + \gamma_1}{\sqrt{h_t}} a_t\right) & \text{cuando } a_t \geq 0 \\ h_t^{\beta_1} \exp\left(\alpha_0 - \gamma_1 \sqrt{2/\pi}\right) \exp\left(\frac{\alpha_1 - \gamma_1}{\sqrt{h_t}} a_t\right) & \text{cuando } a_t < 0. \end{cases} \quad (3.15)$$

La forma exacta de esta curva depende del valor de los parámetros. Para las configuraciones más habituales, las perturbaciones negativas tienen un mayor impacto en la variancia condicional que las positivas de igual magnitud. En el primer caso, esta curva siempre muestra valores mayores a un modelo GARCH, mientras que en el segundo caso comienza con un impacto menor para valores de  $a_t$  positivos pero cercanos a cero hasta el punto en el cual la función exponencial domina la relación cuadrática.

La curva del modelo  $TGARCH(1, 1)$  surge directamente de la [Ecuación \(3.12\)](#),

$$NIC(a_t) = \begin{cases} \alpha_0 + \beta_1 h_t + \alpha_1 a_t^2 & \text{cuando } a_t \geq 0 \\ \alpha_0 + \beta_1 h_t + (\alpha_1 + \gamma_1) a_t^2 & \text{cuando } a_t < 0. \end{cases} \quad (3.16)$$

Similar al modelo GARCH, se trata de una función cuadrática centrada en  $a_t = 0$ , aunque tiene diferentes pendientes para los errores positivos y negativos.

### 3.1.8. Pronósticos

Baillie y Bollerslev (1992) demuestran que el pronóstico óptimo de un retorno bajo un modelo  $ARMA(p, q) - GARCH(m, s)$  es el mismo independientemente que las perturbaciones se supongan homocedásticas o condicionalmente heterocedásticas. Sin embargo, dado que la variancia condicional del retorno es una función de la volatilidad, la amplitud del intervalo de pronóstico para la media varía a lo largo del tiempo. Este último punto justifica la necesidad de calcular el pronóstico óptimo de la variancia condicional.

#### Pronósticos puntuales

Empleando un modelo  $GARCH(1, 1)$  para un pronosticar un paso hacia adelante, tal como luego se hará en la aplicación del [Capítulo 5](#), el pronóstico óptimo dada la información disponible a un determinado momento  $t$  es

$$\hat{h}_{t+1|t} = E \langle h_{t+1} | \mathcal{F}_t \rangle = E \langle \alpha_0 + \alpha_1 a_t^2 + \beta_1 h_t | \mathcal{F}_t \rangle = \alpha_0 + \alpha_1 a_t^2 + \beta_1 h_t = h_{t+1}. \quad (3.17)$$

Se puede demostrar que  $\hat{h}_{t+j|t}$  es función de  $\hat{h}_{t+j-1|t} \forall j > 0$ . Recursivamente, se puede generalizar la [Ecuación \(3.17\)](#) para el pronóstico  $j$  pasos hacia adelante

$$\hat{h}_{t+j|t} = \alpha_0 \sum_{i=0}^{j-2} (\alpha_1 + \beta_1)^i + (\alpha_1 + \beta_1)^{j-1} \hat{h}_{t+1}. \quad (3.18)$$

Si  $\alpha_1 + \beta_1 < 1$ , el proceso GARCH es estacionario en sentido débil y la [Ecuación \(3.18\)](#) puede ser escrita como

$$\hat{h}_{t+j|t} = \sigma^2 + (\alpha_1 + \beta_1)^{j-1} (h_{t+1} - \sigma^2), \quad (3.19)$$

donde  $\sigma^2$  es la variancia marginal de la perturbación y bajo este modelo toma la forma

$$\sigma^2 = V \langle a_t \rangle = \frac{\alpha_0}{1 - \alpha_1 - \beta_1}. \quad (3.20)$$

De allí se desprende que la variancia condicional converge hacia la volatilidad marginal cuando se incrementa el horizonte de pronóstico, es decir

$$\lim_{j \rightarrow \infty} \hat{h}_{t+j|t} = \sigma^2. \quad (3.21)$$

Si los parámetros del modelo son conocidos, las perturbaciones  $a_t$  y las variancias condicionales  $h_t$  pueden ser reconstruidas perfectamente. Por ello, esta familia de modelos es habitualmente conocida como modelos de volatilidad determinística pues no existe incertidumbre sobre  $h_{t+1}$  dados  $\mathcal{F}_t$  y los parámetros del modelo, es decir, no existe un término de error aleatorio en la ecuación de la volatilidad. El término de volatilidad determinística lo contrapone a los modelos de volatilidad estocástica (Taylor, 1994, Ghysels *et al.*, 1996, Shephard, 1996).

En la práctica, los parámetros del modelo y las perturbaciones deben estimarse, de forma que el pronóstico óptimo  $j$  pasos hacia adelante se calcula

$$\hat{h}_{t+j|t} = \hat{\alpha}_0 \sum_{i=0}^{j-2} (\hat{\alpha}_1 + \hat{\beta}_1)^i + (\hat{\alpha}_1 + \hat{\beta}_1)^{j-1} \hat{h}_{t+1}. \quad (3.22)$$

El pronóstico puntual para otros modelos presentados anteriormente puede ser calculado siguiendo el mismo procedimiento pero empleando la especificación para la ecuación de volatilidad propia de cada variante. Por ejemplo, (Franses *et al.*, 2014, p. 197, ec. 7.75) desarrolla el caso de un modelo TGARCH

$$\hat{h}_{t+j|t} = \hat{\alpha}_0 \sum_{i=0}^{j-2} (\hat{\alpha}_1 + 0.5\hat{\gamma}_1 + \hat{\beta}_1)^i + (\hat{\alpha}_1 + 0.5\hat{\gamma}_1 + \hat{\beta}_1)^{j-1} \hat{h}_{t+1}. \quad (3.23)$$

### Pronósticos por intervalos

Como se mencionó anteriormente, la amplitud de los intervalos de pronóstico para los retornos varía a lo largo del tiempo: los períodos de mayor incertidumbre, caracterizados por una mayor variancia condicional, están asociados a intervalos de mayor apertura.

Para un coeficiente de  $1 - \alpha$ , el intervalo de pronóstico está dado por

$$\left( \hat{r}_{t+j} - z_{1-0.5\alpha} \sqrt{V \langle e_{t+j|t} \rangle}, \hat{r}_{t+j} + z_{1-0.5\alpha} \sqrt{V \langle e_{t+j|t} \rangle} \right) \quad (3.24)$$

donde  $z_p$  es el cuantil  $p$  de la función de densidad supuesta para  $\epsilon_t$  y  $e_{t+j|t} = r_{t+j} - \hat{r}_{t+j|t}$  es el error de pronóstico. Este último es función de  $\hat{h}_{t+j|t}$  aunque la forma exacta de la relación depende del modelo elegido para la media.

Como consecuencia natural de la Ecuación (3.21), la variancia del error de pronóstico converge hacia la variancia marginal de la serie de retornos,

$$\lim_{j \rightarrow \infty} V \langle e_{t+j|t} | \mathcal{F}_t \rangle = \sigma^2. \quad (3.25)$$

A diferencia de lo que sucede al suponer homocedasticidad, la convergencia no resulta monótona y  $V \langle e_{t+j}|t \rangle$  puede tomar valores más pequeños que  $V \langle e_{t+j-1}|t \rangle$ . De hecho, la variancia del error de pronóstico bajo el supuesto de heterocedasticidad puede ser mayor o menor que el valor estimado suponiendo homocedasticidad. Intuitivamente, valores grandes para la variancia condicional sugieren que será difícil pronosticar con precisión la media condicional de la serie de retornos, y en tales casos los pronósticos más cortos pueden mostrar intervalos más amplios que aquellos para períodos más alejados en el tiempo.

### 3.1.9. Elección del modelo

El diagnóstico de los residuos guía el proceso de selección de modelos ya que permite identificar debilidades en su especificación.

Retomando lo mencionado en [Sección 3.1.2](#), la especificación GARCH supone que el error estocástico  $\epsilon_t$  está idéntica e independientemente distribuido. En este sentido, los residuos estandarizados deben mostrar las propiedades habituales de variancia constante, falta de autocorrelación y ajuste a la función de densidad.

Adicionalmente resulta de interés probar si el modelo propuesto captura toda la heterocedasticidad condicional en la serie de retornos. Como consecuencia, los residuos estandarizados deben mostrar variancia condicional constante y falta de autocorrelación en su cuadrado. Como alternativa a la habitual prueba de Ljung-Box, [Bollerslev \(1986\)](#) propone una prueba de hipótesis del tipo multiplicador de Lagrange basado en regresiones auxiliares.

Si la función de densidad empleada es simétrica, es posible emplear el conjunto de pruebas mencionadas en la [Sección 2.1.1](#), las cuales fueron diseñadas para detectar ciertas relaciones no lineales en los residuos. En caso de fallar, son un importante indicador para explorar las variantes descriptas en esta sección.

Cuando el objetivo del análisis de datos es principalmente pronosticar, entonces el proceso de elección debe incluir además la evaluación de los pronósticos fuera de la muestra. Esta tarea no resulta sencilla: existen numerosos enfoques alternativos que serán introducidos en el [Capítulo 4](#) y cada analista financiero deberá adaptar a las necesidades de su investigación.

## 3.2. Función de densidad

Todos los modelos presentados suponen que  $\epsilon_t$  es una secuencia de variables aleatorias independiente e idénticamente distribuidas con  $E \langle \epsilon_t \rangle = 0$  y  $V \langle \epsilon_t \rangle = 1$ . No obstante, al momento no se ha explicitado la función de densidad empleada en la estimación de los parámetros y los pronósticos. En la práctica, suelen emplearse las distribuciones gaussiana, t de Student y distribución generalizada del error, tanto en sus versiones simétricas como asimétricas.

### 3.2.1. Distribución gaussiana

La densidad gaussiana define una distribución esférica determinada completamente por los primeros dos momentos, la media  $\mu$  y la variancia  $\sigma^2$ . El soporte de la variable aleatoria es  $x \in \mathbb{R}$  y el espacio paramétrico está conformado por  $\mu \in \mathbb{R}$  y  $\sigma^2 > 0$ . Su forma es simétrica y por definición no tiene exceso de curtosis.

La función de densidad está dada por

$$f(x) = \frac{1}{\sqrt{2\sigma^2\pi}} \exp \left\{ -\frac{(x - \mu)^2}{2\sigma^2} \right\}, \quad (3.26)$$

con media  $E \langle x \rangle = \mu$  y variancia  $V \langle x \rangle = \sigma^2$ . Cuando la perturbación tiene una distribución gaussiana

$$f(a_t | a_{t-1}, \dots, a_0) = \frac{1}{\sqrt{2\pi h_t}} \exp \left\{ -\frac{a_t^2}{2h_t} \right\}, \quad (3.27)$$

la función de log verosimilitud del vector de parámetros de un modelo  $GARCH(1, 1)$

$\Theta = (\alpha_0, \alpha_1, \dots, \alpha_m, \beta_1, \dots, \beta_s)$  es

$$\ell(\theta) = \sum_{t=1}^T \left( -\frac{1}{2} \ln 2\pi - \frac{1}{2} \ln h_t - \frac{a_t^2}{2h_t} \right), \quad (3.28)$$

donde el primer sumando puede ser descartado por no depender de ningún parámetro y la variancia condicional  $h_t$  se calcula recursivamente empleando la ecuación de volatilidad correspondiente al modelo seleccionado (Posedel, 2005).

### 3.2.2. Distribución t de Student

El uso de la distribución t de Student en el ámbito de las series de tiempo fue originalmente propuesto por [Bollerslev \(1987\)](#). Es una distribución unimodal y simétrica que en su versión estandarizada queda completamente determinada por los grados de libertad, aunque suele emplearse una representación con tres parámetros:  $\alpha$  locación,  $\beta$  escala y  $\nu$  forma ([Jackman, 2009](#)). El soporte de la variable aleatoria es  $x \in \mathbb{R}$  y el espacio paramétrico está conformado por  $\alpha \in \mathbb{R}$ ,  $\beta, \nu > 0$ . Tiene coeficiente de simetría nulo y exceso de curtosis equivalente a  $6/(\nu - 4)$  para  $\nu > 4$ ,  $\infty$  para  $2 < \nu \leq 4$  y está indeterminado para otros valores.

La función de densidad para una variable aleatoria  $x$  está dada por

$$f(x) = \frac{\Gamma[(\nu + 1)/2]}{\Gamma(\nu/2)\sqrt{\beta\nu\pi}} \left(1 + \frac{(x - \alpha)^2}{\beta\nu}\right)^{-\frac{\nu+1}{2}}, \quad (3.29)$$

con media  $E\langle x \rangle = \alpha$  y variancia  $V\langle x \rangle = \beta\nu(\nu - 2)^{-1}$ , donde  $\Gamma(x) = (x - 1)!$  es la función Gamma. Cuando la perturbación tiene una distribución t de Student con  $\nu > 2$  grados de libertad

$$f(a_t|a_{t-1}, \dots, a_0) = \frac{\Gamma[(\nu + 1)/2]}{\Gamma(\nu/2)\sqrt{\beta\nu\pi}} \frac{1}{\sqrt{h_t}} \left[1 + \frac{a_t^2}{(\nu - 2)h_t}\right]^{-\frac{\nu+1}{2}}, \quad (3.30)$$

la función de log verosimilitud del vector de parámetros de un modelo  $GARCH(1, 1)$   $\Theta = (\alpha_0, \alpha_1, \dots, \alpha_m, \beta_1, \dots, \beta_s, \nu)$  es

$$\begin{aligned} \ell(\theta) = T \left\{ \ln \left[ \Gamma \left( \frac{\nu + 1}{2} \right) \right] - \ln \left[ \Gamma \left( \frac{\nu}{2} \right) \right] - 0.5 \ln [(\nu - 2) \pi] \right\} \\ - \sum_{t=1}^T \left[ \frac{\nu + 1}{2} \ln \left( 1 + \frac{a_t^2}{(\nu - 2)h_t} \right) + \frac{1}{2} \ln(h_t) \right], \end{aligned} \quad (3.31)$$

permite estimar los grados de libertad  $\nu$  conjuntamente a los restantes parámetros. Si el parámetro  $\nu$  está dado, el término entre corchetes resulta constante a los fines de la optimización y la función de log verosimilitud se reduce al término de la suma.

### 3.2.3. Distribución generalizada del error

La distribución generalizada del error pertenece a la familia exponencial, es unimodal y simétrica. Cuenta con tres parámetros:  $\alpha$  de locación,  $\beta$  de escala y



$\kappa$  de forma. El soporte de la variable aleatoria es  $x \in \mathbb{R}$  y el espacio paramétrico está conformado por  $\alpha \in \mathbb{R}$ ,  $\beta$  y  $\kappa > 0$ .

La función de densidad para una variable aleatoria  $x$  está dada por

$$f(x) = \frac{\kappa \exp \{-0.5 (|x - \alpha|/\beta)^\kappa\}}{2^{1+1/\kappa} \beta \Gamma(1/\kappa)}, \quad (3.32)$$

con media  $E \langle x \rangle = \alpha$ , variancia

$$V \langle x \rangle = \beta^2 2^{2/\kappa} \frac{\Gamma(3/\kappa)}{\Gamma(1/\kappa)}, \quad (3.33)$$

coeficiente de asimetría nulo y curtosis

$$\text{Ku} \langle x \rangle = \frac{\Gamma(5/\kappa)\Gamma(1/\kappa)}{\Gamma(3/\kappa)^2}. \quad (3.34)$$

Despejando el parámetro de escala de la [Ecuación \(3.33\)](#) se arriba a la forma estandarizada, donde

$$\beta = \left( 2^{-2/\kappa} \frac{\Gamma(3/\kappa)}{\Gamma(1/\kappa)} \right)^{\frac{1}{2}}. \quad (3.35)$$

Las colas de la distribución se achatan para valores pequeños de  $\kappa$ . La función de densidad converge en todo punto a la densidad uniforme entre  $(\alpha - \beta, \alpha + \beta)$  cuando  $\kappa \rightarrow \infty$ . Asimismo, equivale a las distribuciones gaussiana y de Laplace para  $\kappa = 2$  y  $\kappa = 1$  respectivamente.

### 3.2.4. Asimetría

Las distribuciones mencionadas anteriormente son unimodales, simétricas y centradas alrededor del cero en sus versiones estandarizadas. Partiendo de ellas, es posible incorporar asimetría a través de un factor inverso de escala en las semirrectas reales positiva y negativa, según lo propuesto por [Fernández y Steel \(1998\)](#). A partir de un parámetro de asimetría  $\xi \in \mathbb{R}^+$ , la función de densidad de una variable aleatoria  $x$  toma la forma

$$f(x|\xi) = \frac{2}{\xi + 1/\xi} [f(\xi x)H(-x) + f(x/\xi)H(x)], \quad (3.36)$$

donde  $H$  es la función escalón de Heaviside. La distribución es asimétrica cuando  $\xi \neq 1$ .

### 3.2.5. Estimación máxima verosímil

Los modelos presentados son no lineales en sus parámetros, de forma que las técnicas de estimación lineal como mínimos cuadrados ordinarios no resultan aplicables. La literatura hace especial foco en la estimación por máxima verosimilitud, aunque algunos autores abordan también la técnica de cuasi-máxima verosimilitud.

La función de verosimilitud depende de la especificación de la volatilidad y la densidad elegidas según se mostró en el presente capítulo. Por ejemplo, [Bollerslev \(1987\)](#) propone que el error estocástico siga una distribución t de Student con  $\nu$  grados de libertad, donde  $\nu$  es un parámetro libre. Otras densidades propuestas son la mezcla de normal y poisson ([Jorion, 1988](#)), distribución generalizada del error ([Nelson, 1991](#)), mezcla de normal y lognormal ([Hsieh, 1989](#)), t de Student asimétrica ([Fernández y Steel, 1998](#)), gaussiana inversa ([Venter y de Jongh, 2002](#)), entre otros.

Por conveniencia, es habitual simplificar el problema de estimación al condicionar la función a las primeras observaciones. Bajo ciertas condiciones de regularidad, la técnica de máxima verosimilitud arroja estimadores consistentes y asintóticamente normales. Además, permite construir un estimador consistente de la matriz de covariancias a partir de la matriz Hessiana obtenida una vez finalizado el proceso de optimización. [Zivot \(2009\)](#) advierte que estas condiciones sólo fueron verificadas para un número limitado de variantes dentro de la familia GARCH. Aun así, es un supuesto frecuentemente empleado en la práctica.

Para un valor dado del vector de parámetros, se puede calcular las variancias condicionales  $h_t$  de forma recursiva y evaluar la log verosimilitud en ese punto. Esta función puede ser maximizada numéricamente empleando métodos como Newton-Raphson y sus modificaciones ([Berndt et al., 1974](#), [Liu y Nocedal, 1989](#)). Alternativamente, es posible calcular su gradiente de forma analítica o mediante un algoritmo de diferenciación numérica, y luego emplear métodos de optimización.

La optimización numérica presenta desafíos y no todos los algoritmos garantizan alcanzar el máximo global. La función de log verosimilitud de los modelos GARCH tiene características poco deseables como máximos locales y zonas

planas en su superficie. La estimación es aún más compleja en el caso de las variantes asimétricas y las densidades que suman dimensiones al espacio paramétrico.

Diversos trabajos encuentran que la elección del algoritmo de optimización, los valores iniciales y los criterios de convergencia son muy influyentes (Fiorentini *et al.*, 1996, McCullough y Renfro, 1998, Brooks *et al.*, 2001). Además, no todos los algoritmos admiten una configuración que asegure una estimación positiva de la variancia y restrinja ciertos parámetros dentro de los límites que garantizan la estacionaridad. Más aún, los algoritmos requieren dar valores iniciales a  $m + s + 1$  parámetros, las perturbaciones y las variancias condicionales. Dado que la elección de estos valores puede causar problemas de convergencia, habitualmente se recomienda reiterar la ejecución con distintos valores a fin de explorar una zona más vasta de la superficie objetivo.

Alternativamente, es posible emplear la técnica de cuasi-verosimilitud, la cual optimiza una función objetivo diferente a la densidad supuesta que presenta propiedades similares. Weiss (1984, 1986), Bollerslev y Wooldridge (1992), Glosten *et al.* (1993) muestran que la optimización de la log verosimilitud gaussiana permite arribar a una estimación consistente y asintóticamente normal para el vector de parámetros incluso cuando la distribución de la perturbación  $a_t$  no es gaussiana, siempre que las ecuaciones de la media y variancia estén correctamente especificadas ( $E \langle \epsilon_t | \mathcal{F}_{t-1} \rangle = 0$  y  $E \langle \epsilon_t^2 | \mathcal{F}_{t-1} \rangle = 1$ ). A pesar de ello, su error estándar presenta menor eficiencia que el estimador de máxima verosimilitud, por lo cual es necesario realizar un ajuste que involucra el estimador "sandwich" (Bollerslev y Wooldridge, 1992). Este último permite estimar la matriz de covariancias de forma consistente, incluso ante la presencia de autocorrelación o heterocedasticidad, y se convirtió en una herramienta estándar de la econometría en los últimos 20 años.

# Capítulo 4

## Evaluación de pronósticos

Comparar la precisión de los pronósticos de diferentes modelos conforma una de las etapas más importantes del proceso de pronóstico. A pesar de ello, durante muchos años la literatura estuvo principalmente enfocada en el diseño de nuevos modelos y sólo recientemente presta mayor atención a la evaluación de los pronósticos. El análisis se nutre mayoritariamente de dos valores, el pronosticado y el realizado, cuya diferencia suele ser llamada error de pronóstico. A la hora de analizar la capacidad de pronóstico de un modelo para la volatilidad, [Poon \(2005\)](#) menciona las cuestiones que el usuario debe considerar:

1. Elección de la variable a pronosticar, es decir variancia o desvío estándar.
2. Ruido introducido por la estimación de la volatilidad realizada, la cual no es observable.
3. Métrica del error de pronóstico que resulta más relevante para el proceso de selección. Forma de penalizar de pronósticos subestimados y sobrestimados.
4. Criterio de selección de un modelo superior en términos de pronósticos, en especial dado que el error de pronóstico es una variable aleatoria en sí misma.
5. Tratamiento de la correlación en el error de pronóstico cuando los parámetros son estimados a partir de un conjunto de datos solapados.

## 4.1. Variable a pronosticar

Poon (2005) sostiene que la variable a pronosticar debe ser el desvío estándar condicional del logaritmo de los retornos. Modelar la variancia condicional podría causar distorsiones en los pronósticos al asignar mayor peso a las variaciones causadas por nuevos shocks, en especial a aquellos de mayor magnitud. Asimismo, la variancia del error de pronóstico de la variancia equivale a la cuarta potencia del desvío estándar del retorno. Las dificultades propias de estimar el cuarto momento complica aún más la evaluación, en especial cuando se emplean distribuciones de colas pesadas. Cuando el error se mide como una variancia, los intervalos de confianza para la media se tornan aún más amplios.

Otros autores han propuesto aplicar una transformación logarítmica sobre el parámetro de volatilidad a fin de reescalar los errores de pronóstico, originando distorsiones en la función de pérdida. En opinión de Poon, esto puede considerarse excesivo porque la magnitud del error tiene un impacto directo en los modelos de valuación de activos, los procesos de administración del riesgo y las decisiones de inversión, en especial dado que el inversor es adverso al riesgo y los grandes desvíos.

## 4.2. Función de pérdida

Idealmente, el proceso de evaluación de pronósticos debe reflejar la utilidad que éstos tienen para el inversor, sea en términos relativos o absolutos. Sin embargo, ello requiere un conocimiento preciso del proceso de decisión, incluyendo las funciones de costo y beneficio. En consecuencia, casi la totalidad de los trabajos científicos se limitan a aplicar métricas estadísticas.

Sea  $\hat{\sigma}_t$  la medida de volatilidad histórica para el período  $t$  y  $\sqrt{\hat{h}_t}$  la volatilidad pronosticada para el mismo momento. A continuación, se presentan algunas de las funciones de pérdida más habituales.

El error de pronóstico son el Error Medio (*Mean Error* - ME)

$$\text{ME} = \frac{1}{T} \sum_{t=1}^T (\sqrt{\hat{h}_t} - \hat{\sigma}_t) \quad (4.1)$$

mide el desvío promedio. Conserva la dirección de los errores, por lo cual también se lo considera una medida del sesgo. Dado que las diferencias positivas y negativas pueden cancelarse, un Error Medio nulo no indica pronósticos perfectos sino la inexistencia de sesgos. Es una medida dependiente de la escala de medición y la transformación aplicada a los datos. Todos los errores son penalizados equitativamente. Los valores deseables son cercanos a cero.

Similarmente, el Error Cuadrático Medio (*Mean Squared Error* - MSE) está dado por

$$\text{MSE} = \frac{1}{T} \sum_{t=1}^T \left( \sqrt{\hat{h}_t} - \hat{\sigma}_t \right)^2. \quad (4.2)$$

Los errores con signo contrario no se cancelan, de forma que el estadístico presenta una medida global del error de pronóstico pero no indica su dirección. Al ser una función cuadrática, penaliza los errores más extremos y enfatiza que el error total de pronóstico está afectado ampliamente por las grandes diferencias individuales. Depende de la escala de medición y la transformación aplicada a los datos. Su relación con el núcleo de la densidad gaussiana la convierte en una medida útil a pesar de ser poco intuitiva y difícil de interpretar. Esta función de pérdida depende del error de pronóstico  $\sqrt{\hat{h}_t} - \hat{\sigma}_t$ , el cual está aproximadamente centrado en cero y tiene una variancia proporcional al cuadrado de la variancia de los retornos. Esto último lo torna un estimador sensible a observaciones extremas y el nivel de volatilidad de los retornos.

Algunos autores proponen el uso de la función logarítmica para disminuir el efecto de valores extremos. Por ejemplo, el Logaritmo del Error Cuadrático Medio (*Log Mean Squared Error* - LMSE) viene dado por

$$\text{LMSE} = \frac{1}{T} \sum_{t=1}^T \left( \ln \sqrt{\hat{h}_t} - \ln \hat{\sigma}_t \right)^2. \quad (4.3)$$

Naturalmente surge la Raíz del Error Cuadrático Medio (*Root Mean Squared Error* - RMSE)

$$\text{RMSE} = \sqrt{\frac{1}{T} \sum_{t=1}^T \left( \sqrt{\hat{h}_t} - \hat{\sigma}_t \right)^2}, \quad (4.4)$$

para la cual valen todas las propiedades del Error Cuadrático Medio. La medición se realiza en la misma unidad que la variable de interés, facilitando su interpretación.

Si bien el Error Cuadrático Medio puede resultar un criterio lógico al momento de evaluar pronósticos para la media, [Bollerslev y Ghysels \(1996\)](#) tienen reparos en cuanto a su utilidad en un contexto de heterocedasticidad. Por lo tanto, proponen una versión ajustada bajo el nombre de Error Heterocedástico Cuadrático Medio (*Heteroskedastic Mean Squared Error* - HMSE)

$$\text{HMSE} = \frac{1}{T} \sum_{t=1}^T \left( \frac{\hat{\sigma}_t}{\sqrt{\hat{h}_t}} - 1 \right)^2. \quad (4.5)$$

Esta medida se asimila al cuadrado del error porcentual, aunque el error de pronóstico es escalado por la volatilidad pronosticada. Por lo tanto, no resulta adecuada cuando la magnitud forma parte clave del análisis.

El Error Absoluto Medio surge como una alternativa a las penalizaciones cuadráticas (*Mean Absolute Error* - MAE)

$$\text{MAE} = \frac{1}{T} \sum_{t=1}^T \left| \sqrt{\hat{h}_t} - \hat{\sigma}_t \right|. \quad (4.6)$$

También conocido como desvío absoluto medio, es una medida de la magnitud global del error de pronóstico. No provee información de la dirección del error pues las diferencias de signo contrario no se cancelan. Penaliza todos los errores en proporción a su magnitud. Depende de la escala de medición y la transformación aplicada a los datos. Los valores deseables son cercanos a cero.

Por su parte, el Error Porcentual Absoluto Medio (*Mean Absolute Percent Error* - MAPE)

$$\text{MAPE} = \frac{1}{T} \sum_{t=1}^T \frac{\left| \sqrt{\hat{h}_t} - \hat{\sigma}_t \right|}{\hat{\sigma}_t}, \quad (4.7)$$

es una medida relativa independiente de la escala de medición pero afectada por la transformación de los datos. No revela información sobre el signo del error y penaliza las diferencias de forma proporcional.

[Pagan y Schwert \(1990\)](#) en su famoso trabajo proponen modificar la escala del error de pronóstico aplicando la transformación logarítmica. Como tal, surge el Logaritmo del Error Absoluto Medio (*Mean Log Absolute Error* - LMAE)

$$\text{MLAE} = \frac{1}{T} \sum_{t=1}^T \ln \left| \sqrt{\hat{h}_t} - \hat{\sigma}_t \right|, \quad (4.8)$$

el cual resulta menos sensible a valores extremos.

La función de pérdida de Cuasi-Verosimilitud (*Quasi-Likelihood* - QLIKE) está definida como

$$\text{QLIKE} = \frac{1}{T} \sum_{t=1}^T \left( \ln \sqrt{\hat{h}_t} + \frac{\hat{\sigma}_t}{\sqrt{\hat{h}_t}} \right). \quad (4.9)$$

Está basada en el error de pronóstico estandarizado  $\hat{\sigma}_t/\sqrt{\hat{h}_t}$ , el cual está aproximadamente centrado en 1 y, suponiendo normalidad, tiene variancia 2 independientemente de la volatilidad de los retornos. Por ello, se muestra menos sensible a valores extremos en comparación al Error Cuadrático Medio.

El coeficiente de desigualdad de Theil, también llamado incertidumbre o competencia, es una medida de asociación basada en el concepto de entropía. Al comparar la información mutua de la variable observada y pronosticada en relación a la entropía de la variable pronosticada, se constituye como un coeficiente normalizado de información mutua e indica la fracción de la volatilidad histórica que es pronosticada por el modelo. El estadístico está especificado por

$$U_1 = \frac{\sqrt{\frac{1}{T} \sum_{t=1}^T (\sqrt{\hat{h}_t} - \hat{\sigma}_t)^2}}{\sqrt{\frac{1}{T} \sum_{t=1}^T \sqrt{\hat{h}_t}^2} + \sqrt{\frac{1}{T} \sum_{t=1}^T \hat{\sigma}_t^2}}, \quad (4.10)$$

y está acotado al rango  $[0, 1]$ . Es una medida independiente de la escala de medición y la transformación aplicada a los datos. Valores cercanos a cero indican mayor precisión en el pronóstico.

La razón de excesos permite evaluar la predicción del Valor en Riesgo. Se establece que el límite del valor en riesgo fue excedido cuando el retorno observado al momento  $t$  es menor al valor en riesgo pronosticado para la probabilidad  $p$ , es decir

$$v_t = \begin{cases} 0 & \text{cuando } r_t \geq \text{VaR}(p, t) \\ 1 & \text{cuando } r_t < \text{VaR}(p, t) \end{cases}. \quad (4.11)$$

La calidad del pronóstico es evaluada en función de la cantidad relativa de



excesos medida como la razón entre los observados y los esperados:

$$\text{VR} = \frac{\sum_{t=1}^T v_t}{pT}. \quad (4.12)$$

Intuitivamente, el modelo sobrepronostica o subpronostica el riesgo cuando el coeficiente es menor o mayor a uno, respectivamente. Se han desarrollado diversos procedimientos de inferencia. La prueba de cobertura marginal permite confirmar si el coeficiente es significativamente distinto de uno, mientras que la prueba de independencia compara si los excesos observados son independientes o forman conglomerados (Daníelsson, 2011). Más allá de las reglas formales, los agentes del mercado suelen opinar que el modelo es preciso cuando  $\text{VR} \in [0.80, 1.20]$  e impreciso cuando  $\text{VR} < 0.50 \vee \text{VR} > 1.50$ , intervalos que se comprimen cuando el tamaño del horizonte de pronóstico fuera de la muestra se incrementa.

Las razones de acierto (*hit ratios*) miden la habilidad del pronóstico para anticipar cambios direccionales en la volatilidad. Sean  $T^+$  y  $T^-$  la cantidad total de incrementos y decrementos en la volatilidad histórica  $\hat{\sigma}_t$  del período fuera de la muestra. La razón de aciertos positivos se define como

$$\text{Hit}^+ = \frac{1}{T^+} \sum_{t=1}^{T^+} \mathbb{I}_{((\sqrt{h}-\hat{\sigma}_t)(\hat{\sigma}_{t+1}-\hat{\sigma}_t)>0)} \times \mathbb{I}_{(\hat{\sigma}_{t+1}-\hat{\sigma}_t>0)} \quad (4.13)$$

y, similarmente, la razón de aciertos negativos es

$$\text{Hit}^- = \frac{1}{T^-} \sum_{t=1}^{T^-} \mathbb{I}_{((\sqrt{h}-\hat{\sigma}_t)(\hat{\sigma}_{t+1}-\hat{\sigma}_t)>0)} \times \mathbb{I}_{(\hat{\sigma}_{t+1}-\hat{\sigma}_t<0)}. \quad (4.14)$$

Cuando no se desea diferenciar la dirección del acierto, se evalúa la media de la correcta predicción del cambio de dirección (Mean Correct Prediction of Direction of Change - MCPDC)

$$\text{MCPDC} = \frac{1}{T} (T^+ \text{Hit}^+ + T^- \text{Hit}^-). \quad (4.15)$$

### 4.3. Estimadores imperfectos de la volatilidad

El uso de estimadores condicionalmente insesgados pero imperfectos para la volatilidad puede afectar la comparación del error de pronóstico. Patton (2011) estudia la distorsión que diferentes estimadores de la volatilidad histórica causan

en algunas funciones de pérdida. Además, deduce las condiciones necesarias y suficientes que una función de pérdida debe cumplir para que el ranking de pronósticos entre diferentes modelos sea robusto a la presencia de ruido en el estimador de la volatilidad. Finalmente, encuentra ciertos casos especiales de estas funciones robustas que incluyen el Error Cuadrático Medio y la pérdida de Cuasi-Verosimilitud.

El uso de estimadores condicionalmente insesgados como los presentados en la [Sección 2.2](#) intenta resolver, al menos en parte, el inconveniente de comparar los pronósticos con valores realizados de una variable no observable. A partir de simulaciones, [Hansen y Lunde \(2006\)](#) concluyen que conjugar funciones de pérdida no robustas y estimadores poco eficientes puede resultar problemático para el proceso de selección de pronósticos. Distintos autores han demostrado que las comparaciones basadas en los estimadores y el verdadero valor de la variable latente no siempre arrojan conclusiones consistentes. [Andersen y Bollerslev \(1998\)](#) y [Andersen \*et al.\* \(2005\)](#), entre otros, estudian la reducción del poder de las pruebas de hipótesis ante la presencia de ruido muestral en los estimadores de la volatilidad histórica.

Similarmente, [Hansen y Lunde \(2006\)](#) estudian las distorsiones en el ordenamiento de los modelos según su capacidad de pronóstico y algunas pruebas de hipótesis frecuentemente empleadas. Notan que emplear diferentes estimadores de la variable latente influencia el orden de los pronósticos y derivan las condiciones que aseguran la equivalencia entre los rangos conformados tomando como referencia el verdadero valor del parámetro y el estimador.

El problema a resolver es encontrar aquél pronóstico puntual que minimiza la pérdida esperada condicionada al conjunto de información disponible a un momento dado. Es decir,

$$\sqrt{\hat{h}_t^*} \equiv \arg \min_{\sqrt{\hat{h}_t} \in \mathcal{H}} \mathbb{E} \left\langle \mathcal{L} \left( \hat{\sigma}_{t+j}, \sqrt{\hat{h}_t} \right) \mid \mathcal{F}_t \right\rangle, \quad (4.16)$$

donde  $\sqrt{\hat{h}_t^*}$  es el pronóstico óptimo,  $\mathcal{H}$  es el conjunto de todos los posibles pronósticos,  $\mathcal{L}$  es una función de pérdida dada y  $\mathcal{F}_t$  es el conjunto de información disponible al momento  $t$ . En general, gran parte de los trabajos científicos hacen foco en encontrar un pronóstico óptimo para una función de pérdida dada. En

este caso, Patton reconoce que el interés yace principalmente en el estimador de la volatilidad y, por lo tanto, resuelve la [Ecuación \(4.16\)](#) para encontrar la función de pérdida óptima.

Si el orden de dos pronósticos comparados con un estimador de la volatilidad es igual a aquél que se obtiene al emplear el verdadero valor de la variancia condicional, entonces es posible comparar la precisión media de los pronósticos incluso cuando la variable de interés no es observable. Una función de pérdida es robusta si el ordenamiento por pérdida esperada de dos pronósticos de volatilidad  $\sqrt{\hat{h}_{1,t+j|t}}$  y  $\sqrt{\hat{h}_{2,t+j|t}}$  no cambia si se emplea el verdadero valor de la variancia condicional  $\sigma_{t+j}^2$  o bien un estimador condicionalmente insesgado  $\hat{\sigma}_{t+j}^2$ . Es decir,

$$\begin{aligned} \mathbb{E} \left\langle \mathcal{L} \left( \sigma_{t+j}^2 \sqrt{\hat{h}_{1,t+j|t}} \right) \right\rangle \geq \mathbb{E} \left\langle \mathcal{L} \left( \sigma_{t+j}^2, \sqrt{\hat{h}_{2,t+j|t}} \right) \right\rangle &\iff \\ \mathbb{E} \left\langle \mathcal{L} \left( \hat{\sigma}_{t+j}^2, \sqrt{\hat{h}_{1,t+j|t}} \right) \right\rangle \geq \mathbb{E} \left\langle \mathcal{L} \left( \hat{\sigma}_{t+j}^2, \sqrt{\hat{h}_{2,t+j|t}} \right) \right\rangle, \end{aligned} \quad (4.17)$$

para todo  $\hat{\sigma}_{t+j}^2$  tal que  $\mathbb{E} \left\langle \hat{\sigma}_{t+j}^2 | \mathcal{F}_{t-1} \right\rangle = \sigma_{t+j}^2$ . Aunque una función robusta genera un orden invariante al ruido en el estimador de la volatilidad, el nivel de la pérdida esperada es mayor si se emplea un estimador de la variancia histórica en lugar del verdadero valor del parámetro.

Anteriormente, [Meddahi \(2001\)](#) muestra que el coeficiente de determinación  $R^2$  de Mincer-Zarnowitz es robusto al ruido en  $\hat{\sigma}_t^2$ . En cambio, [Hansen y Lunde \(2006\)](#) observan que el coeficiente para una regresión que aplica la transformación logarítmica en ambos lados de la ecuación no lo es. Aunque Patton encuentra que el Error Cuadrático Medio y la pérdida de Cuasi-Verosimilitud son funciones robustas cuando se aplican sobre los retornos cuadrados, el Error Cuadrático Medio aplicado al desvío estándar no es una medida robusta y la distorsión se incrementa cuanto mayor sea el exceso de curtosis de la distribución de los retornos. Empleando el estimador de variancia realizada de [Andersen \*et al.\* \(2003\)](#) y los estimadores de rangos, encuentra que emplear estimadores más eficientes reducen el nivel de la distorsión para todas las funciones de pérdidas.

Su principal contribución es encontrar las condiciones suficientes y necesarias para obtener una función de pérdida robusta. El desarrollo teórico arroja una familia infinita de funciones que admite penalidades tanto simétricas como asimétricas. Asimismo, concluye que el Error Cuadrático Medio es la única fun-

ción robusta que depende exclusivamente del error de pronóstico, mientras que la pérdida de Cuasi-Verosimilitud es la única función robusta que depende solamente del error de pronóstico estandarizado. La primera medida es más sensible a valores extremos que la segunda. Por último, el artículo detalla las condiciones para que una función robusta sea considerada homogénea, es decir invariante a las unidades de medición.

## 4.4. Comparación de pronósticos

A la hora de evaluar modelos, es importante distinguir entre pronósticos dentro y fuera de la muestra. Los primeros están basados en un modelo estimado en función de todos los datos recolectados e implícitamente suponen que los parámetros son estables a lo largo del tiempo. En el caso de los procesos estocásticos financieros, las fluctuaciones en los parámetros es un punto crítico en todo proceso de modelización y, por lo tanto, la evaluación debe realizarse con los pronósticos fuera de la muestra.

Cuando el número de observaciones  $T$  es lo suficientemente grande, existen dos formas de construir los pronósticos fuera de la muestra para un modelo dado. En el enfoque recursivo, se fija un número inicial de observaciones  $n$ , se emplea el subconjunto de datos  $\{1, \dots, n\}$  para la estimación del modelo y se computa el pronóstico para el período  $n + 1$ . En la segunda iteración, se emplea el subconjunto  $\{1, \dots, n, n + 1\}$  para estimar los parámetros y se pronostica el valor al momento  $n + 2$ . En la última iteración, se emplea todo el conjunto salvo por la última observación  $\{1, \dots, T - 1\}$  y se pronostica el valor para el período fuera de la muestra  $T$ . En cambio, el enfoque móvil mantiene un tamaño fijo para el conjunto de datos empleados en la estimación del modelo. De esta manera, los subconjuntos  $\{1, \dots, n\}$ ,  $\{2, \dots, n + 1\}$  y  $\{T - n, \dots, T - 1\}$  son empleados en la primera, segunda y última iteración respectivamente.

Los parámetros que gobiernan los procesos financieros no son estables a lo largo del tiempo. De hecho, los agentes económicos adaptan constantemente sus expectativas y previsiones a las condiciones cambiantes del mercado. En consecuencia, la segunda alternativa es más popular entre los analistas pues omite

la información más distante y captura el nivel actual de los parámetros. Además, ofrece una reducción en el tiempo computacional que puede resultar importante en ciertos contextos. La elección del enfoque empleado afecta las características del error de los pronósticos, de forma que algunas pruebas mencionadas más adelante son aplicables en un determinado esquema.

La comparación de los pronósticos se realiza en base a los estadísticos mencionados en la [Sección 4.2](#). Estos a su vez están sujetos a error y ruido, motivo por el cual sólo puede concluirse estadísticamente respecto de ellos en función de pruebas de significación. [West \(1996\)](#), [West y Cho \(1995\)](#), [West y McCracken \(1998\)](#) derivan el error estándar para las funciones de Error Medio, Error Cuadrático Medio, Error Absoluto Medio y Raíz Cuadrada del Error Cuadrático Medio, incluyendo correcciones por correlación serial en los errores de pronóstico y la incertidumbre inherente a la estimación de la volatilidad histórica. [Poon \(2005\)](#) advierte que esta metodología está basada en la teoría asintótica y sólo funciona en el esquema recursivo.

#### 4.4.1. Pruebas de Diebold-Mariano

[Diebold y Mariano \(1995\)](#) proponen tres pruebas para la hipótesis de igualdad en la precisión de los pronósticos generados por dos modelos. Fueron desarrolladas en base a la teoría de muestras finitas y resultan más apropiadas para el esquema de ventana móvil. Las mismas relacionan el error de pronóstico con una función de pérdida y miden el diferencial entre los dos modelos que compiten.

Estas pruebas incluyen una forma asintótica que corrige la correlación serial. Diferentes trabajos de simulación muestran que es robusta ante errores de pronóstico no-gaussianos que tienen media distinta de cero, así como también ante la existencia de correlación serial y contemporánea. Además, los autores proveen dos formas exactas para muestras finitas basadas en las pruebas de signo y rango con signos de Wilcoxon, las cuales mostraron un rendimiento aceptable en simulaciones con muestras pequeñas.

Sea  $y_t$  el valor observado de la variable,  $\hat{y}_{it}$  y  $\hat{y}_{ij}$  los valores pronosticados,  $e_{it}$  e  $e_{jt}$  los errores de pronóstico asociados para las unidades de tiempo  $t = 1, \dots, T$

y los modelos  $i$  y  $j$ . Sea  $g(\cdot)$  la función de pérdida

$$g(y_t, \hat{y}_{it}) = g(e_{it}), \quad (4.18)$$

y  $d_t$  la diferencia de la pérdida

$$d_t = g(e_{it}) - g(e_{jt}). \quad (4.19)$$

La hipótesis nula supone igualdad en la precisión de los pronósticos y se traduce en un diferencial nulo  $E \langle d_t \rangle = 0$ . Cuando  $d_t$  es una serie estacionaria en sentido débil y de corta memoria, es posible emplear la teoría de grandes muestras para deducir la distribución asintótica de los estimadores que son función de ella.

### Prueba asintótica

La primera prueba está basada en el diferencial medio

$$\bar{d} = \frac{1}{T} \sum_{t=1}^T |g(e_{it}) - g(e_{jt})|, \quad (4.20)$$

el cual toma valor cero en la hipótesis nula.

El estadístico está dado por

$$S_{1a} = \frac{\bar{d}}{\sqrt{T^{-1} 2\pi \hat{f}_d(0)}}, \quad (4.21)$$

$$2\pi \hat{f}_d(0) = \sum_{\tau=-(T-1)}^{T-1} l\left(\frac{\tau}{S(T)}\right) \hat{\gamma}_d(\tau), \quad (4.22)$$

$$\hat{\gamma}_d(\tau) = \frac{1}{T} \sum_{t=|\tau|+1}^T (d_t - \bar{d})(d_{t-|\tau|} - \bar{d}), \quad (4.23)$$

donde  $f_d(0)$  es la densidad espectral de la función diferencial de pérdida para la frecuencia cero y  $\gamma_d(\tau)$  es la función de autocovariancia del diferencial de pérdida para el rezago  $\tau$ .  $S(T)$  es el valor que trunca el operador de la ventana de rezagos

$$l\left(\frac{\tau}{S(T)}\right) = \begin{cases} 1 & \text{si } \left|\frac{\tau}{S(T)}\right| \leq 1 \\ 0 & \text{en otro caso.} \end{cases} \quad (4.24)$$

Los autores mencionan que el pronóstico óptimo  $j$  pasos hacia adelante muestra dependencia a lo sumo para el rezago  $j - 1$  y, por lo tanto, recomiendan una ventana para el rezago rectangular y uniforme con  $S(T) = j - 1$ . El estimador  $\hat{f}_d(0)$  podría tomar valores negativos con baja probabilidad: en tal caso sugieren tomar su valor como cero y rechazar automáticamente la hipótesis nula.

La distribución asintótica del estadístico bajo la hipótesis nula es  $S_{1a} \stackrel{a}{\sim} N(0, 1)$ .

### Prueba de signos

La segunda prueba fue desarrollada para aquellos casos donde el número de pronósticos fuera de la muestra es pequeño. Está basada en la mediana del diferencial de pérdida

$$\text{med}(d_t) = \text{med}(g(e_{it}) - g(e_{jt})), \quad (4.25)$$

la cual toma valor cero en la hipótesis nula. Vale destacar que una mediana nula para el diferencial no implica necesariamente que el diferencial de las pérdidas medianas también lo sea. Sólo cuando  $d_t$  se distribuye simétricamente, la mediana y la media son equivalentes y la relación se torna bidireccional.

Si el diferencial está independiente e idénticamente distribuido, la cantidad de valores positivos observados en una muestra de tamaño dado tiene una distribución binomial con parámetros  $T$  y  $p = 0.5$  bajo la hipótesis nula. Entonces, el estadístico

$$S_2 = \sum_{t=1}^T \mathbb{I}_{(d_t > 0)}. \quad (4.26)$$

puede ser comparado con una tabla acumulada de la distribución binomial. En el caso de muestras grandes, es posible lograr una aproximación empleando la versión studentizada del estadístico

$$S_{2a} = \frac{S_2 - 0.5T}{\sqrt{0.25T}}, \quad (4.27)$$

el cual tiene una distribución asintótica normal estándar bajo la hipótesis nula  $S_{2a} \stackrel{a}{\sim} N(0, 1)$ .

## Prueba de signos y rangos

Al igual que la prueba de signos y rangos de Wilcoxon, es de libre distribución pero requiere que el diferencial de las pérdidas sea simétrico. Cuando este supuesto se cumple, tiene más poder que la prueba de signos.

Suponiendo que el diferencial  $d_t$  está independiente e idénticamente distribuido, el estadístico está definido como la suma de los rangos del valor absoluto para las observaciones positivas

$$S_3 = \sum_{t=1}^T \mathbb{I}_{(d_t > 0)} \text{ran}(|d_t|). \quad (4.28)$$

Los valores críticos tabulados son invariantes a la distribución del diferencial de pérdida pues sólo requiere que esté centrada en cero y sea simétrica. En el caso de muestras grandes, es posible lograr una aproximación empleando la versión studentizada del estadístico

$$S_{3a} = \frac{S_3 - \frac{T(T+1)}{4}}{\sqrt{\frac{T(T+1)(2T+1)}{24}}}, \quad (4.29)$$

la cual tiene una distribución asintótica normal estándar bajo la hipótesis nula  $S_{3a} \stackrel{a}{\sim} N(0, 1)$ .

## Consideraciones generales

Las pruebas enunciadas presentan ciertas ventajas. En primer lugar, son válidas para una amplia clase de funciones de pérdidas. En particular, no exigen que sea cuadrática, simétrica o continua. Asimismo, los estadísticos admiten muchas de las características que se observan frecuentemente en los errores de pronósticos, incluyendo media distinta de cero, distribución diferente a la gaussiana y correlación contemporánea. Este último punto es importante porque los pronósticos comparados corresponden a una misma serie de tiempo, y además fueron estimados en función de un mismo conjunto de información.

Sólo el estadístico  $S_{1a}$  admite correlación serial en los diferenciales. Para las restantes pruebas, la existencia de correlación implica que todos los posibles



arreglos de los valores observados no son igualmente probables y, en consecuencia, rompe con el supuesto de aleatorización. Esto requiere la aplicación de técnicas de corrección, por ejemplo Bonferroni.

Las pruebas de Diebold-Mariano suponen que el diferencial de pérdidas es estacionario en covarianza. Dos décadas después de su artículo original, [Diebold \(2012\)](#) mencionan algunas limitaciones. Los pronósticos no siempre resultan óptimos y, por lo tanto, puede existir cierta correlación entre los errores. Esto puede traducirse en un diferencial estacionario, salvo que las series de pronósticos estén cointegradas producto de ser generadas por diferentes modelos estimados a partir de un mismo conjunto de datos. De todas formas, el grado de adecuación a los supuestos por parte de un conjunto de datos puede ser verificado a través de ciertas técnicas de validación.

#### 4.4.2. Pruebas de ortogonalidad

El uso de regresiones para medir el contenido de información de los pronósticos es posiblemente el enfoque más popular en los trabajos sobre la volatilidad. [Mincer y Zarnowitz \(1969\)](#) proponen el modelo de regresión lineal

$$\hat{\sigma}_t = \beta_0 + \beta_1 \sqrt{\hat{h}_{1,t+j|t}} + \eta_t, \quad (4.30)$$

donde  $\hat{\sigma}_t$  es la volatilidad histórica del período  $t$  estimada mediante alguna de las alternativas mencionadas en la [Sección 2.2](#) y  $\eta_t$  es un término de error. Los pronósticos son condicionalmente insesgados si los coeficientes toman conjuntamente los valores  $\beta_0 = 0$  y  $\beta_1 = 1$ .

Cuando los pronósticos están solapados, el término de error muestra heterocedasticidad y correlación serial, motivo por el cual el error estándar suele ser estimado según lo propuesto por [Hansen y Hodrick \(1980\)](#). Sea  $\mathbf{Y}$  la matriz  $T \times 2$  de los regresores incluyendo la ordenada al origen, entonces  $\mathbf{Y}_t = \left(1 \sqrt{\hat{h}_{1,t+j|t}}\right)$  es un vector fila  $1 \times 2$ . Sea  $Q(k, t)$  una función indicadora que toma valor 1 cuando existe superposición entre  $\mathbf{Y}_k$  e  $\mathbf{Y}_t$ .

Se construye

$$\hat{\Psi} = \frac{1}{T} \sum_{t=1}^T \eta_t^2 \mathbf{Y}_t' \mathbf{Y}_t + \frac{1}{T} \sum_{k=1}^T \sum_{t=k+1}^T Q(k, t) \eta_k \eta_t (\mathbf{Y}_t' \mathbf{Y}_k + \mathbf{Y}_k' \mathbf{Y}_t), \quad (4.31)$$

donde,  $\eta_k$  y  $\eta_t$  son los residuos para las observaciones  $k$  y  $t$ . Entonces, la matriz de covariancia ajustada para los coeficientes de la regresión está dada por

$$\hat{\Omega} = (\mathbf{Y}'\mathbf{Y})^{-1}\hat{\Psi}(\mathbf{Y}'\mathbf{Y})^{-1}. \quad (4.32)$$

Aunque es útil contar con pronósticos insesgados, es importante distinguir entre sesgo y poder de pronóstico. Un valor sesgado puede ser un pronóstico valioso una vez corregido, sin embargo uno insesgado es poco útil si el error es muy grande. Idealmente, la variancia del término de error  $\eta_t$  debe ser pequeña y el coeficiente de determinación cercano a uno.

Cuando existen más de un modelo, es posible probar el poder explicativo marginal adicionando los pronósticos al lado derecho de la [Ecuación \(4.30\)](#). De esta forma, se considera que el primer pronóstico resume toda la información contenida en los restantes si no existe un incremento significativo del coeficiente de determinación ajustado. Alternativamente, es posible realizar una prueba de ortogonalidad haciendo una regresión de los residuos de la [Ecuación \(4.30\)](#) contra otros pronósticos.

# Capítulo 5

## Aplicación al mercado de acciones en Argentina

A partir de las características distintivas que las acciones presentan en término de retornos y volatilidad, se han propuesto diferentes variantes a los modelos de heterocedasticidad condicional que intentan capturar los hechos estilizados. La especificación de la ecuación de volatilidad y la función de densidad conforman la principal decisión de modelado que el estadístico debe tomar. El objetivo de esta sección es identificar en qué grado estas opciones contribuyen a lograr pronósticos más precisos.

### 5.1. Introducción

Se seleccionan las acciones más líquidas entre aquellas listadas en el Mercado de Valores de Buenos Aires: Petróleo Brasileiro (APBR), Banco Macro (BMA), Sociedad Comercial del Plata (COME), Empresa Distribuidora y Comercializadora Norte (EDN), Siderar (ERAR), Banco Francés (FRAN), Grupo Financiero Galicia (GGAL), Pampa Energía (PAMP), Telecom (TECO2), Tenaris (TS), YPF (YPFD). Las mismas representan el 84 % del volumen negociado para el período que comienza el 1 de enero del 2009 y finaliza el 31 de mayo del 2016. Asimismo, se incluye el Índice Merval, índice bursátil que mide el valor en pesos argentinos de una cartera de acciones que cotizan en la Bolsa de Comercio

de Buenos Aires. Se emplea la serie diaria de precios homogéneos de apertura, mínimo, máximo y cierre para la plaza de negociación con liquidación en 72 horas hábiles. Las series están compuestas por aproximadamente 1.760 observaciones cada una, salvo por YPF que cuenta con 1.718 valores. En todos los casos, los datos faltantes se producen en días donde una especie no tiene cotización y son eliminados de la serie. Se preprocesan los datos truncando los retornos logarítmicos al 1%. Los estadísticos resúmenes son mostrados en el [Cuadro 5.1](#). El conjunto de datos fue obtenido de Bolsar, el portal financiero de la Bolsa de Comercio de Buenos Aires.

## 5.2. Hechos estilizados

La presente sección recorre los hechos estilizados recopilados en el [Capítulo 2](#) e identifica hasta qué punto aplican en el mercado bajo análisis. Las conclusiones están respaldadas por los cuadros y las figuras del [Anexo A](#). Aquellos análisis más sensibles a la existencia de valores extremos son presentados en forma comparativa para la serie original y los datos truncados. Las pruebas de hipótesis se realizan con un nivel de significación del 5% salvo que se explicita lo contrario.

### 5.2.1. Dependencia

En la mitad de las series se rechaza la hipótesis nula de independencia hasta el décimo rezago en los retornos, en favor de la hipótesis alternativa de autocorrelación lineal. Aunque la estimación de la función de autocorrelación está influenciada por valores extremos, no se observan mayores discrepancias entre los datos originales y los valores truncados. En todos los casos, se manifiesta dependencia no lineal en la forma de autocorrelación lineal en el cuadrado de los retornos.

Respecto de la asimetría en la volatilidad, los estadísticos de [Engle y Ng \(1993\)](#) se muestran sensibles a los valores extremos. Empleando los datos originales, cinco series muestran un efecto conjunto significativo: una de ellas en el tamaño de los retornos positivos, dos en el tamaño de los retornos negativos y dos en el signo. Muchos de estos efectos desaparecen al emplear los retornos


Estadístico	APBR	BMA	COME	EDN	ERAR	FRAN	GGAL	MERVAL	PAMP	TECO2	TS	YFPD
Comienzo	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09
Fin	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16
Observaciones	1761	1761	1758	1760	1757	1761	1761	1760	1761	1760	1761	1718
Mínimo	-0.0999	-0.0795	-0.0957	-0.1012	-0.0802	-0.0906	-0.0818	-0.0680	-0.0842	-0.0733	-0.0692	-0.1050
Máximo	0.0969	0.0944	0.1197	0.1353	0.0884	0.0935	0.0964	0.0592	0.0903	0.0803	0.0747	0.0952
Media	-0.0000	0.0018	0.0014	0.0017	0.0016	0.0022	0.0024	0.0015	0.0015	0.0015	0.0012	0.0009
Mediana	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0013	0.0000	0.0000	0.0010	0.0000
Desvío Estándar	0.0308	0.0289	0.0314	0.0344	0.0262	0.0292	0.0281	0.0201	0.0282	0.0248	0.0232	0.0290
Asimetría	-0.0602	0.1037	0.4690	0.5111	0.2418	0.0974	0.1793	-0.1925	0.2531	0.1041	0.0435	-0.1873
Curtosis	4.1913	3.6805	4.9522	4.8376	4.2404	3.8674	4.1044	4.2225	3.8465	3.9540	3.8606	5.0516
Jarque-Bera	105.2049	37.1414	343.6055	324.2411	129.7569	57.9887	98.9224	120.4656	71.3829	69.9196	54.8953	311.3595
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	10.3592	12.2093	52.8959	25.4388	42.5167	22.1357	13.7899	16.7822	16.8568	18.5732	14.0138	31.5109
p-valor	0.4096	0.2713	<0.0001	0.0046	<0.0001	0.0144	0.1828	0.0793	0.0776	0.0460	0.1724	0.0005
$r^2$ Ljung-Box (10)	646.5971	119.1916	110.4961	398.4184	128.5955	152.7904	126.8474	196.9947	297.3537	74.6875	180.2686	281.6528
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (22)	30.9216	20.7013	58.7923	41.4417	61.8027	29.8661	29.4462	40.8220	26.7565	30.4109	29.8874	48.4020
p-valor	0.0977	0.5393	<0.0001	0.0073	<0.0001	0.1218	0.1326	0.0087	0.2206	0.1088	0.1212	0.0010
$r^2$ Ljung-Box (22)	1268.4235	171.5481	131.5174	542.8665	171.2340	194.0528	142.7125	274.4000	457.2796	123.1809	319.7672	346.6283
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Sesgo del signo	1.4999	1.4552	0.5227	1.4231	0.4914	0.3787	0.8646	1.1352	0.0664	2.2956	1.7178	0.4900
p-valor	0.1338	0.1458	0.6012	0.1549	0.6232	0.7049	0.3874	0.2564	0.9471	0.0218	0.0860	0.6242
Sesgo de tamaño negativo	0.8933	0.6518	0.2974	0.9546	0.0563	0.5521	0.7437	1.2691	1.2806	3.6300	1.1702	1.6577
p-valor	0.3718	0.5146	0.7662	0.3399	0.9551	0.5809	0.4572	0.2046	0.2005	0.0003	0.2421	0.0976
Sesgo de tamaño positivo	0.1852	1.0931	0.5220	0.4109	0.1209	0.0969	0.6633	0.6528	1.9986	0.5368	0.0046	0.4220
p-valor	0.8531	0.2745	0.6018	0.6812	0.9038	0.9228	0.5072	0.5139	0.0458	0.5915	0.9963	0.6731
Efecto conjunto	3.6628	2.2499	0.3829	3.8676	0.7887	0.3169	1.0241	12.1311	6.3778	13.5230	4.1554	5.0429
p-valor	0.3003	0.5222	0.9437	0.2761	0.8522	0.9568	0.7954	0.0069	0.0946	0.0036	0.2452	0.1687

**Cuadro 5.1:** Estadísticos resumen para la serie de retornos (datos truncados al 1%). Elaboración propia.

truncados. Las acciones TECO2 presentan un efecto conjunto significativo explicado por el sesgo en el signo y en el tamaño de los retornos negativos, a la vez que el índice Merval sólo muestra un efecto conjunto significativo.

### 5.2.2. Distribución paramétrica

Para todas las series, la prueba de Jarque-Bera rechaza la hipótesis de simetría y exceso de curtosis nulo. Ni los datos originales, ni los truncados, tienen similitud con una distribución gaussiana. El coeficiente de asimetría aplicado a datos truncados muestra que nueve series tienen una distribución asimétrica hacia la derecha, es decir con frecuentes pérdidas pequeñas y pocas grandes ganancias. Los datos originales muestran leptocurtosis. Se destaca YPFD por tener la mayor curtosis con un coeficiente de 14.1385. Los valores extremos identificados en la [Figura 5.1](#) afectan fuertemente al estadístico, el cual se reduce a 5.0516 cuando se toman los datos truncados.



**Figura 5.1:** Valores extremos (YPFD). Izquierda: Serie histórica del retorno logarítmico. Los puntos azules destacan aquellas observaciones que serían truncadas al 1%. Las líneas marcan el valor del cuantil. Derecha: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. Elaboración propia.

## 5.3. Análisis de modelos

Interesa conocer si los diferentes modelos diseñados para dar respuesta a los hechos estilizados mejoran la capacidad de predicción respecto de un modelo base parametrizado como  $ARMA(1,1) - GARCH(1,1)$  con distribución gaussiana para el error aleatorio.


### 5.3.1. Estimación de la volatilidad

Los estimadores estudiados en la [Sección 2.2](#) aplicados a la serie de datos bajo estudio muestran asimetría hacia la derecha, es decir el mercado se encuentra con mayor frecuencia en un estado de baja volatilidad. En términos generales, los diferentes estimadores de volatilidad siguen un mismo patrón y parecen congruentes entre sí. El estimador cierre a cierre tiende a mostrar valores más extremos en ambos sentidos, mientras que en determinados períodos el estimador de Yang-Zhang se aleja de otras medidas para mostrar valores mayores al resto.

Al igual que [Brandt y Kinlay \(2005\)](#), en las series analizadas se observa una fuerte correlación lineal para estimaciones contemporáneas. El estimador de cierre a cierre es aquél con mayor grado de variabilidad. Aunque difiere un tanto de los restantes, alcanza una correlación estimada superior al 0.60. En contraposición, los estimadores basados en distancias se observan muy estrechamente relacionados entre sí con coeficientes de correlación estimados mayores a 0.90.

Si bien este estadístico de asociación no es robusto a la presencia de valores extremos, para la generalidad de los casos no se observan grandes diferencias en su valor cuando se emplean datos truncados. No obstante, el proceso de limpieza de los datos resulta clave para COME. Como puede verse en la [Figura A.18](#), se identifican diez observaciones consecutivas con valores extremos para el estimador de Yang-Zhang. Las correlaciones del [Cuadro A.6](#) y el [Cuadro A.7](#) del Anexo muestran diferencias de gran magnitud.

Considerando que los estimadores muestran un comportamiento similar, y alentado además por las conclusiones de [Brandt y Kinlay \(2005\)](#), se toma como única referencia el estimador de Parkinson de la [Ecuación \(2.30\)](#) para simplificar lo que resta de la aplicación. De contar con datos de alta frecuencia, el estimador



**Figura 5.2:** Volatilidad de COME (transversal). Matriz de gráficos de dispersión para la volatilidad diaria estimada por los estimadores cierre a cierre, Parkinson, Garman-Klass, Rogers-Satchell y Yang-Zhang. En todos los casos se emplea una ventana móvil de diez observaciones. Elaboración propia.

de la volatilidad realizada de [Andersen \*et al.\* \(2003\)](#) ofrecería una referencia más precisa.

### 5.3.2. Modelos de heterocedasticidad condicional

Se filtra cada serie de tiempo a través de un modelo de heterocedasticidad condicional. Se define una ecuación para la media del tipo  $ARMA(1, 1)$  a fin de eliminar la eventual correlación serial entre los retornos. Se especifican diferentes ecuaciones para la volatilidad correspondiente a los modelos GARCH, EGARCH, GJRGARCH, TGARCH y NGARCH, todos ellos de orden  $m = 1$  y  $s = 1$ . Asimismo, se emplean las distribuciones gaussiana, t de Student y generalizada del error, en sus versiones simétricas y asimétricas. Todas las estimaciones



son realizadas por máxima verosimilitud a través de un conjunto de algoritmos numéricos implementados por el paquete rugarch ([Ghalanos, 2015](#)) corrido en R 3.3.1 ([R Core Team, 2016](#)). Se excluyen del análisis tres casos por falta de convergencia: parametrización GJRGARCH con densidades gaussianas simétrica y asimétrica para COME y NGARCH con densidad t de Student asimétrica para Merval.

### 5.3.3. Diagnóstico de residuos

Los residuos estandarizados del modelo base son analizados desde distintos puntos de vista a fin de identificar fallas en los supuestos claves: distribución del error aleatorio, especificación de la volatilidad y asimetría.

En primer lugar, se desea estudiar si la función de densidad elegida para el error aleatorio resulta adecuada. Se estudia la forma de la distribución en términos de los estimadores puntuales de los primeros cuatro momentos. Luego, se aplica la prueba de Jarque-Bera para probar la hipótesis nula que establece que los coeficientes de asimetría y curtosis se asimilan a una gaussiana. Asimismo, se emplea la prueba de bondad de ajuste  $\chi^2$  de Pearson con 50 celdas a fin de probar si los residuos observados difieren de la función de densidad teórica. Se visualiza un histograma y el gráfico de cuantil-cuantil para evaluar la bondad del ajuste.

En segundo lugar, se analiza si el modelo logra capturar todo el efecto de la correlación serial en los retornos. A través de la prueba de Ljung-Box aplicada a los residuos en los primeros 10 y 22 rezagos, se verifica si la ecuación para la media  $ARMA(1,1)$  resulta suficiente. Similarmente, la misma prueba aplicada al cuadrado de las perturbaciones permite confirmar si la especificación  $GARCH(1,1)$  captura la heterocedasticidad condicional. Se muestran los correlogramas para complementar el análisis.

En tercer lugar, se estudia si los residuos evidencian asimetría, o bien si la especificación simétrica para la volatilidad es adecuada. Para ello, se emplean las pruebas de [Engle y Ng \(1993\)](#). Además, se grafica la curva de impacto de noticias observada y aquella que surge del modelo paramétrico.

Todas estas herramientas permiten identificar si uno o más supuestos del

modelo base falla. En tal caso, se proponen diversas alternativas para la especificación de la volatilidad y la función de densidad. Todos los modelos son comparados por su bondad de ajuste dentro de la muestra a través de los criterios de información de Akaike y Bayesiano.

#### 5.3.4. Evaluación de pronósticos

Para cada modelo propuesto se genera un pronóstico fuera de la muestra de la volatilidad  $\sqrt{\hat{h}_{t+j|t}}$  para  $j = 1$  paso hacia adelante. Este proceso es repetido 500 veces con una ventana móvil que incluye aproximadamente 1250 observaciones de entrenamiento. Los parámetros son estimados en cada iteración.

Se evalúan los pronósticos en tres sentidos. A nivel direccional, se emplean los estadísticos de razón de acierto para movimientos positivos, negativos y medios a fin de comprender la capacidad del modelo para predecir si la volatilidad se incrementará o disminuirá en el próximo período. Por su parte, se emplean diversas funciones de pérdida para evaluar el error de predicción, a saber Error Cuadrático Medio, Cuasi-Verosimilitud y  $R^2$  de Mincer-Zarnowitz. Finalmente, dado que el pronóstico puntual de la volatilidad se emplea para el pronóstico por intervalos de los retornos, se desea conocer si el modelo propuesto produce intervalos más precisos. Para ello, se compara la cantidad de observaciones fuera de la muestra que exceden el VaR al 1% contra la cantidad esperada.

Los procesos de diagnóstico de los residuos y evaluación de pronósticos son realizados para cada serie y luego resumidos en el [Cuadro 5.2](#). Para una acción dada, estos dos análisis en su conjunto permiten comprender si la mejora del ajuste dentro de la muestra se traduce en una mayor capacidad de pronóstico.

### 5.4. Casos de aplicación

A continuación se detallan los resultados más destacados de la aplicación realizada a las acciones de las empresas seleccionadas y el índice Merval. Para mayor facilidad, la narrativa sólo transcribe los valores más relevantes que guían al análisis. No obstante, se sugiere una lectura conjunta al [Anexo B](#), el cual recopila los cuadros y las figuras con la información que da soporte a la

investigación.

### 5.4.1. APBR

Los residuos estandarizados del modelo base muestran simetría ( $\hat{s} = -0.0853$ ) y moderado exceso de curtosis ( $\hat{k} = 3.8960$ ). Aunque el estadístico de Jarque-Bera  $\hat{JB} = 61.0200$  ( $< 0.0001$ ) rechaza la hipótesis nula de normalidad en los residuos, la prueba de bondad de ajuste  $\chi^2$  de Pearson  $\hat{\chi}^2 = 46.9800$  (0.5555) no implica rechazo.

Los estadísticos de Ljung-Box para los primeros 10 y 22 rezagos  $\hat{LB}_{z,10} = 4.4870$  (0.9227) y  $\hat{LB}_{z,22} = 17.3300$  (0.7451) no rechazan la hipótesis nula de ausencia de autocorrelación en los residuos estandarizados. Lo mismo sucede con los estadísticos  $\hat{LB}_{z^2,10} = 9.2120$  (0.5121) y  $\hat{LB}_{z^2,22} = 24.1900$  (0.3373) aplicados al cuadrado de los residuos estandarizados.

A la hora de estudiar el efecto apalancamiento, no se verifica la existencia de efectos individuales en las magnitudes negativas  $\hat{t}_{tam-} = 1.2118$ (0.2257) y las magnitudes positivas  $\hat{t}_{tam+} = 0.1904$ (0.8490). En contraposición, la prueba del sesgo en el signo  $\hat{t}_{signo} = 2.1929$  (0.0284) muestra evidencia suficiente de asimetría. Sin perjuicio de encontrar resultados mixtos, la prueba conjunta  $\hat{F} = 6.2340$  (0.1008) no rechaza la simetría.

En resumen, el modelo logra capturar todo el efecto de la autocorrelación en los retornos y la heterocedasticidad condicional. En cambio, no ajusta las colas largas en las perturbaciones. Los datos podrían requerir la incorporación del efecto apalancamiento en el modelo.

Se proponen diversas alternativas para resolver las deficiencias relevadas. Las colas pesadas sugieren emplear las densidades asimétricas t de Student y distribución generalizada del error. Se proponen modelos con ecuaciones no lineales para la volatilidad.

Los criterios de información de Akaike y Bayesiano seleccionan a los modelos eGARCH y GARCH con distribución t de Student. En todos los casos la prueba de bondad de ajuste  $\chi^2$  no rechaza la hipótesis nula sobre la distribución supuesta.

Si bien estos modelos resuelven algunas de las limitaciones identificadas en

el modelo base, tienen un efecto más bien mixto en el poder predictivo. Los estadísticos direccionales y las medidas de error medio resultan similares.

No obstante, el principal perjuicio se verifica en la amplitud de los intervalos para la media, lo cual se refleja en un comportamiento errático en la cantidad de excesos al VaR para el 1 %. En general, los modelos basados en densidad con colas pesadas sobreestiman el ancho de los intervalos de predicción.

### 5.4.2. BMA

Los residuos estandarizados del modelo base muestran leve asimetría ( $\hat{s} = 0.1241$ ) y marcado exceso de curtosis ( $\hat{k} = 3.5570$ ). Los estadísticos de Jarque-Bera  $\hat{J}B = 27.31$  ( $< 0.0001$ ) y bondad de ajuste  $\chi^2$  de Pearson  $\hat{\chi}^2 = 94.2800$  ( $< 0.0001$ ) rechazan la hipótesis nula de normalidad en los residuos.

Los estadísticos de Ljung-Box para los primeros 10 y 22 rezagos  $\hat{L}B_{z,10} = 5.7590$  (0.8351) y  $\hat{L}B_{z,22} = 11.3100$  (0.9701) no rechazan la hipótesis nula de ausencia de autocorrelación en los residuos estandarizados. Lo mismo sucede con los estadísticos  $\hat{L}B_{z^2,10} = 5.5530$  (0.8513) y  $\hat{L}B_{z^2,22} = 13.5500$  (0.9165) aplicados al cuadrado de los residuos estandarizados.

A la hora de estudiar el efecto apalancamiento, no se verifica la existencia de efectos individuales en el signo  $\hat{t}_{signo} = 1.4550$  (0.1458), las magnitudes negativas  $\hat{t}_{tam-} = 0.6520$  (0.5145) y las magnitudes positivas  $\hat{t}_{tam+} = 1.0932$  (0.2745). La prueba conjunta  $\hat{F} = 2.2500$  (0.5221) permite concluir en un mismo sentido.

En resumen, el modelo logra capturar todo el efecto de la autocorrelación en los retornos y la heterocedasticidad condicional. En cambio, no ajusta la asimetría y las colas largas en las perturbaciones. Los datos no requieren la incorporación del efecto apalancamiento en el modelo.

Se proponen diversas alternativas para resolver las deficiencias relevadas. La existencia conjunta de asimetría y colas pesadas sugiere emplear las densidades asimétricas t de Student y distribución generalizada del error.

Los criterios de información de Akaike y Bayesiano seleccionan a los modelos GARCH con distribución generalizada del error, tanto simétrica como asimétrica. Aunque esta densidad muestra mejor aproximación que la gaussiana, la prueba de bondad de ajuste  $\chi^2$  rechaza la hipótesis nula sobre la distribución supuesta.

Si bien estos modelos resuelven algunas de las limitaciones identificadas en el modelo base, no necesariamente presentan un mayor poder predictivo. Los estadísticos direccionales resultan prácticamente idénticos. Similarmente, las medidas de error medio de pronóstico no evidencian mejoras.

No obstante, se verifica que la elección de la función de densidad afecta directamente la amplitud de los intervalos para la media, lo cual se refleja en una gran mejora en la cantidad de excesos al VaR para el 1%. Mientras que el modelo base triplica la cantidad de excesos esperada, el mismo modelo estimado con la distribución del error generalizada reduce la cantidad de excesos en dos terceras partes. Aun así, el pronóstico resulta poco preciso.


### 5.4.3. COME

Los residuos estandarizados del modelo base muestran una asimetría marcada ( $\hat{s} = 0.4695$ ) y muy fuerte exceso de curtosis ( $\hat{k} = 5.0510$ ). Los estadísticos de Jarque-Bera  $\hat{JB} = 372.7000$  ( $< 0.0001$ ) y bondad de ajuste  $\chi^2$  de Pearson  $\hat{x}^2 = 188.7000$  ( $< 0.0001$ ) rechazan la hipótesis nula de normalidad en los residuos.

Los estadísticos de Ljung-Box para los primeros 10 y 22 rezagos  $\hat{LB}_{z,10} = 19.9300$  (0.0299) y  $\hat{LB}_{z,22} = 25.0700$ (0.2937) sugieren la presencia de autocorrelación en los residuos estandarizados para los primeros diez rezagos pero no así para el segundo caso. Complementando el análisis con la [Figura 5.3](#), se requiere inspeccionar con mayor detenimiento los rezagos  $\tau = 1$  y  $\tau = 10$ . Por su parte, los estadísticos  $\hat{LB}_{z^2,10} = 6.9220$  (0.7328) y  $\hat{LB}_{z^2,22} = 24.1200$  (0.3407) no rechazan la hipótesis nula de ausencia de autocorrelación en el cuadrado de los residuos estandarizados.

A la hora de estudiar el efecto apalancamiento, no se verifica la existencia de efectos individuales en el signo  $\hat{t}_{signo} = 0.5240$  (0.6003), las magnitudes positivas  $\hat{t}_{tam+} = 0.5235$ (0.6007) y las magnitudes negativas  $\hat{t}_{tam-} = 0.2979$ (0.7658). La prueba conjunta  $\hat{F} = 0.3849$  (0.9433) permite concluir en el mismo sentido.

En resumen, el modelo no logra capturar todo el efecto de la autocorrelación en los retornos pero sí la existencia de heterocedasticidad condicional. En cambio, no replica la asimetría y las colas largas en las perturbaciones. Los datos no requieren la incorporación del efecto apalancamiento en el modelo.



**Figura 5.3:** Autocorrelación de residuos (COME). Izquierda: Autocorrelograma para los residuos. Derecha: Autocorrelograma para el cuadrado de los residuos. Elaboración propia.

Se proponen diversas alternativas para resolver las deficiencias relevadas. El fuerte exceso de curtosis sugiere emplear la distribución generalizada del error. Al presentarse asimetrías, se proponen modelos con una especificación asimétrica para la función de volatilidad como así también la versión asimétrica de la función de densidad.

Los criterios de información de Akaike y Bayesiano seleccionan respectivamente a los modelos GJRGARCH y GARCH con distribución generalizada del error en su parametrización asimétrica. El segundo criterio selecciona una ecuación más simple para la volatilidad producto de la mayor penalización al parámetro adicional del GJRGARCH. En todos los casos la prueba de bondad de ajuste  $\chi^2$  rechaza la hipótesis nula sobre la distribución supuesta.

Si bien estos modelos tampoco cumplen con la totalidad de sus supuestos, logran una mejor aproximación respecto del modelo base y además presentan un mayor poder predictivo. Los estadísticos direccionales se incrementan levemente, aunque otros modelos como el eGARCH verifican mejoras substanciales. Las medidas de error medio de pronóstico evidencian mejoras, en especial el  $R^2$  de Mincer-Zarnowitz mejora de 0.2983 a 0.4562 y 0.4701 respectivamente.

Se verifica además que la elección de la función de densidad afecta directa-

mente la amplitud de los intervalos para la media, lo cual se refleja en una gran mejora en la cantidad de excesos al VaR para el 1 %. Mientras que el modelo base duplica la cantidad de excesos esperada, los modelos seleccionados muestran 6 excesos contra los 5 esperados.

#### 5.4.4. EDN

Los residuos estandarizados del modelo base muestran una asimetría marcada ( $\hat{s} = 0.4055$ ) y fuerte exceso de curtosis ( $\hat{k} = 4.2670$ ). Los estadísticos de Jarque-Bera  $\hat{JB} = 165.9000$  ( $< 0.0001$ ) y bondad de ajuste  $\chi^2$  de Pearson  $\hat{x}^2 = 148.8000$  ( $< 0.0001$ ) rechazan la hipótesis nula de normalidad en los residuos. Los estadísticos de Ljung-Box para los primeros 10 y 22 rezagos  $\hat{LB}_{z,10} = 9.1000$  (0.5227) y  $\hat{LB}_{z,22} = 20.5900$  (0.5463) no rechazan la hipótesis nula de ausencia de autocorrelación en los residuos estandarizados. Lo mismo sucede con los estadísticos  $\hat{LB}_{z^2,10} = 9.6520$  (0.4716) y  $\hat{LB}_{z^2,22} = 16.0600$  (0.8131) aplicados al cuadrado de los residuos estandarizados.

A la hora de estudiar el efecto apalancamiento, no se verifica la existencia de efectos individuales en el signo  $\hat{t}_{signo} = 1.4220$  (0.1551), las magnitudes positivas  $\hat{t}_{tam+} = 0.4110$  (0.6810) y las magnitudes negativas  $\hat{t}_{tam-} = 0.9533$  (0.3405). La prueba conjunta  $\hat{F} = 3.8670$  (0.2762) permite concluir en un mismo sentido.

En resumen, el modelo logra capturar todo el efecto de la autocorrelación en los retornos y la heterocedasticidad condicional. En cambio, no ajusta la asimetría y las colas largas en las perturbaciones. Los datos no requieren la incorporación del efecto apalancamiento en el modelo.

Se proponen diversas alternativas para resolver las deficiencias relevadas. El fuerte exceso de curtosis sugiere emplear la distribución generalizada del error y t de Student, siempre en sus variantes asimétricas. No obstante, también se ajustan modelos con una especificación asimétrica para la función de volatilidad.

Los criterios de información de Akaike y Bayesiano seleccionan el modelo GARCH con distribución generalizada del error asimétrica. En términos generales, se observa que la bondad de ajuste de esta función de distribución supera la distribución t de Student para todas las variantes. En todos los casos la prueba de bondad de ajuste  $\chi^2$  rechaza la hipótesis nula sobre la distribución supuesta.

Si bien estos modelos resuelven algunas de las limitaciones identificadas en el modelo base, no necesariamente presentan un mayor poder predictivo. Los estadísticos direccionales, las medidas de error medio y los excesos al VaR para el 1 % resultan muy similares.

### 5.4.5. ERAR

Los residuos estandarizados del modelo base muestran una leve asimetría ( $\hat{s} = 0.2811$ ) y fuerte exceso de curtosis ( $\hat{k} = 4.2260$ ). Los estadísticos de Jarque-Bera  $\hat{JB} = 133.1000$  ( $< 0.0001$ ) y bondad de ajuste  $\chi^2$  de Pearson  $\hat{x}^2 = 117.0200$  ( $< 0.0001$ ) rechazan la hipótesis nula de normalidad en los residuos. Los estadísticos de Ljung-Box para los primeros 10 y 22 rezagos  $\hat{LB}_{z,10} = 11.1300$  (0.3478) y  $\hat{LB}_{z,22} = 24.0700$  (0.3436) no rechazan la hipótesis nula de ausencia de autocorrelación en los residuos estandarizados. Lo mismo sucede con los estadísticos  $\hat{LB}_{z^2,10} = 4.5280$  (0.9204) y  $\hat{LB}_{z^2,22} = 21.7100$  (0.4773) aplicados al cuadrado de los residuos estandarizados.

A la hora de estudiar el efecto apalancamiento, no se verifica la existencia de efectos individuales en el signo  $\hat{t}_{signo} = 0.4913$  (0.6233), las magnitudes negativas  $\hat{t}_{tam-} = 0.0564$  (0.9550) y las magnitudes positivas  $\hat{t}_{tam+} = 0.1217$  (0.9032). La prueba conjunta  $\hat{F} = 0.7896$  (0.8520) permite concluir en un mismo sentido.


En resumen, el modelo logra capturar todo el efecto de la autocorrelación en los retornos y la heterocedasticidad condicional. En cambio, no ajusta la asimetría y las colas largas en las perturbaciones. Los datos no requieren la incorporación del efecto apalancamiento en el modelo.

Se proponen diversas alternativas para resolver las deficiencias relevadas. El exceso de curtosis sugiere emplear la distribución generalizada del error y t de Student, siempre en sus variantes asimétricas. No obstante, también se ajustan modelos con una especificación asimétrica para la función de volatilidad.

Los criterios de información de Akaike y Bayesiano seleccionan respectivamente a los modelos GJRGARCH y GARCH con distribución generalizada del error en su parametrización asimétrica. El segundo criterio selecciona una ecuación más simple para la volatilidad producto de la mayor penalización que aplica al parámetro adicional del GJRGARCH. La prueba de bondad de ajuste



$\chi^2$  no rechaza la hipótesis nula sobre la distribución supuesta. Tal como se observa en la [Figura 5.4](#), la aproximación muestra una gran mejora a pesar de un desvío manifiesto.



**Figura 5.4:** Distribución de residuos (ERAR). Izquierda: Histograma de los retornos logarítmicos. Centro: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. Derecha: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución generalizada del error asimétrica. Elaboración propia.

Si bien estos modelos resuelven algunas de las limitaciones identificadas en el modelo base, no necesariamente presentan un mayor poder predictivo. Los estadísticos direccionales, las medidas de error medio y los excesos al VaR para el 1% resultan muy similares.

#### 5.4.6. FRAN

Los residuos estandarizados del modelo base muestran una muy leve asimetría ( $\hat{s} = 0.1134$ ) y moderado exceso de curtosis ( $\hat{k} = 3.7080$ ). Los estadísticos de Jarque-Bera  $\hat{J}B = 40.5500$  ( $< 0.0001$ ) y bondad de ajuste  $\chi^2$  de Pearson  $\hat{\chi}^2 = 89.4000$  (0.0004) rechazan la hipótesis nula de normalidad en los residuos. Los estadísticos de Ljung-Box para los primeros 10 y 22 rezagos  $\hat{L}B_{z,10} = 12.0100$  (0.2844) y  $\hat{L}B_{z,22} = 21.0400$  (0.5181) no rechazan la hipótesis nula de ausencia de autocorrelación en los residuos estandarizados. Lo mismo sucede con los estadísticos  $\hat{L}B_{z^2,10} = 5.8570$  (0.8271) y  $\hat{L}B_{z^2,22} = 15.1500$  (0.8557) aplicados al cuadrado de los residuos estandarizados.

A la hora de estudiar el efecto apalancamiento, no se verifica la existencia de efectos individuales en el signo  $\hat{t}_{signo} = 0.3781$  (0.7054), las magnitudes negativas

$\hat{t}_{tam-} = 0.5512(0.5815)$  y las magnitudes positivas  $\hat{t}_{tam+} = 0.0973(0.9225)$ . La prueba conjunta  $\hat{F} = 0.3160 (0.9570)$  permite concluir en un mismo sentido.

En resumen, el modelo logra capturar todo el efecto de la autocorrelación en los retornos y la heterocedasticidad condicional. En cambio, no ajusta la asimetría y las colas largas en las perturbaciones. Los datos no requieren la incorporación del efecto apalancamiento en el modelo.

Se proponen diversas alternativas para resolver las deficiencias. El exceso de curtosis sugiere emplear la distribución generalizada del error y t de Student. A pesar de una asimetría leve, se observan mejores ajustes dentro de la muestra para las variantes asimétricas de las funciones de densidad. No obstante, también se ajustan modelos con una especificación asimétrica para la función de volatilidad.

Los criterios de información de Akaike y Bayesiano seleccionan respectivamente a los modelos NGARCH y GARCH con distribución generalizada del error en su parametrización asimétrica. El segundo criterio selecciona una ecuación más simple para la volatilidad producto de la mayor penalización que aplica al parámetro adicional del GJRGARCH. La prueba de bondad de ajuste  $\chi^2$  no rechaza la hipótesis nula sobre la distribución supuesta.

Si bien estos modelos resuelven algunas de las limitaciones identificadas en el modelo base, no necesariamente presentan un mayor poder predictivo. Los estadísticos direccionales resultan prácticamente idénticos. Similarmente, las medidas de error medio de pronóstico no evidencian mejoras.

No obstante, se verifica que la elección de la función de densidad afecta directamente la amplitud de los intervalos para la media, lo cual se refleja en una pequeña mejora en la cantidad de excesos al VaR para el 1%. Para una cantidad esperada de 5 excesos, el modelo base presenta 12 y los modelos seleccionados 9.

#### 5.4.7. GGAL

Los residuos estandarizados del modelo base muestran una muy leve asimetría ( $\hat{s} = 0.1139$ ) y moderado exceso de curtosis ( $\hat{k} = 3.8600$ ). Los estadísticos de Jarque-Bera  $\hat{JB} = 58.1400 (< 0.0001)$  y bondad de ajuste  $\chi^2$  de Pearson  $\hat{\chi}^2 = 96.2100 (< 0.0001)$  rechazan la hipótesis nula de normalidad en los residuos. Los estadísticos de Ljung-Box para los primeros 10 y 22 rezagos  $\hat{LB}_{z,10} =$

7.9180 (0.6369) y  $\hat{LB}_{z,22} = 22.9500(0.4043)$  no rechazan la hipótesis nula de ausencia de autocorrelación en los residuos estandarizados. Lo mismo sucede con los estadísticos  $\hat{LB}_{z^2,10} = 5.4970 (0.8556)$  y  $\hat{LB}_{z^2,22} = 16.4300 (0.7940)$  aplicados al cuadrado de los residuos estandarizados.

A la hora de estudiar el efecto apalancamiento, no se verifica la existencia de efectos individuales en el signo  $\hat{t}_{signo} = 0.8643 (0.3875)$ , las magnitudes negativas  $\hat{t}_{tam-} = 0.7425(0.4579)$  y las magnitudes positivas  $\hat{t}_{tam+} = 0.6634(0.5072)$ . La prueba conjunta  $\hat{F} = 1.0226 (0.7958)$  permite concluir en un mismo sentido.

En resumen, el modelo logra capturar todo el efecto de la autocorrelación en los retornos y la heterocedasticidad condicional. En cambio, no ajusta la asimetría y las colas largas en las perturbaciones. Los datos no requieren la incorporación del efecto apalancamiento en el modelo.

Se proponen diversas alternativas para resolver las deficiencias relevadas. El exceso de curtosis sugiere emplear la distribución generalizada del error y t de Student. Dado que la asimetría es leve, se prueban las densidades simétricas y asimétricas. También se ajustan modelos con una especificación asimétrica para la función de volatilidad.

Los criterios de información de Akaike y Bayesiano seleccionan respectivamente a los modelos GJRGARCH y GARCH con distribución generalizada del error en su parametrización asimétrica. El segundo criterio selecciona una ecuación más simple para la volatilidad producto de la mayor penalización que aplica al parámetro adicional del GJRGARCH. La prueba de bondad de ajuste  $\chi^2$  no rechaza la hipótesis nula sobre la distribución supuesta.

Si bien estos modelos resuelven algunas de las limitaciones identificadas en el modelo base, no necesariamente presentan un mayor poder predictivo. Los estadísticos direccionales resultan prácticamente idénticos. Similarmente, las medidas de error medio de pronóstico no evidencian mejoras.

No obstante, se verifica que la elección de la función de densidad afecta directamente la amplitud de los intervalos para la media, lo cual se refleja en una pequeña mejora en la cantidad de excesos al VaR para el 1%. Para una cantidad esperada de 5 observaciones, el modelo base presenta 11, GJRGARCH 9 y GARCH 10.

### 5.4.8. MERVAL

Los residuos estandarizados del modelo base muestran una leve asimetría negativa ( $\hat{s} = -0.2176$ ) y moderado exceso de curtosis ( $\hat{k} = 3.9270$ ). Los estadísticos de Jarque-Bera  $\hat{J}B = 76.8900$  ( $< 0.0001$ ) y bondad de ajuste  $\chi^2$  de Pearson  $\hat{x}^2 = 85.5100$  (0.0010) rechazan la hipótesis nula de normalidad en los residuos. Los estadísticos de Ljung-Box para los primeros 10 y 22 rezagos  $\hat{L}B_{z,10} = 13.7300$  (0.1856) y  $\hat{L}B_{z,22} = 32.9400$ (0.0627) no rechazan la hipótesis nula de ausencia de autocorrelación en los residuos estandarizados. Lo mismo sucede con los estadísticos  $\hat{L}B_{z^2,10} = 13.6240$  (0.1909) y  $\hat{L}B_{z^2,22} = 27.2300$  (0.2027) aplicados al cuadrado de los residuos estandarizados.

A la hora de estudiar el efecto apalancamiento, no se verifica la existencia de efectos individuales en el signo  $\hat{t}_{signo} = 1.1358$  (0.2562), las magnitudes negativas  $\hat{t}_{tam-} = 1.2683$ (0.2049) y las magnitudes positivas  $\hat{t}_{tam+} = 0.6533$ (0.5136). En cambio, la prueba conjunta  $\hat{F} = 12.1320$  (0.0069) rechaza la hipótesis de nula de inexistencia de efecto apalancamiento.

En resumen, el modelo logra capturar todo el efecto de la autocorrelación en los retornos y la heterocedasticidad condicional. En cambio, no ajusta la asimetría y las colas largas en las perturbaciones. Los datos requieren la incorporación del efecto apalancamiento en el modelo.

Se proponen diversas alternativas para resolver las deficiencias relevadas. El exceso de curtosis sugiere emplear la distribución generalizada del error. La asimetría es leve pero podría estar asociada al efecto apalancamiento, con lo cual se prueban las densidades simétricas y asimétricas y además se hace especial énfasis en aquellos modelos con ecuaciones no lineales para la volatilidad.

El criterio de información de Akaike selecciona los modelos EGARCH y GJR-GARCH, mientras que el criterio Bayesiano prefiere el modelo GARCH, en todos los casos con distribución generalizada del error simétrica. El segundo criterio selecciona una ecuación más simple para la volatilidad producto de la mayor penalización que aplica al parámetro adicional del EGARCH y GJR-GARCH. En todos los casos, la prueba de bondad de ajuste  $\chi^2$  no rechaza la hipótesis nula sobre la distribución supuesta.

Si bien estos modelos resuelven algunas de las limitaciones identificadas en

el modelo base, no necesariamente presentan un mayor poder predictivo. Los estadísticos direccionales resultan prácticamente idénticos. Similarmente, las medidas de error medio no evidencian mejoras.

No obstante, se verifica que la elección de la función de densidad afecta directamente la amplitud de los intervalos para la media, lo cual se refleja en una pequeña mejora en la cantidad de excesos al VaR para el 1%. Para una cantidad esperada de 5 observaciones, el modelo base presenta 14, eGARCH 11, GJRGARCH 12 y GARCH 11.

#### 5.4.9. PAMP

Los residuos estandarizados del modelo base muestran moderada asimetría ( $\hat{s} = 0.3209$ ) y moderado exceso de curtosis ( $\hat{k} = 3.7930$ ). Los estadísticos de Jarque-Bera  $\hat{JB} = 76.4000$  ( $< 0.0001$ ) y bondad de ajuste  $\chi^2$  de Pearson  $\hat{\chi}^2 = 172.4000$  ( $< 0.0001$ ) rechazan la hipótesis nula de normalidad en los residuos. Los estadísticos de Ljung-Box para los primeros 10 y 22 rezagos  $\hat{LB}_{z,10} = 11.0000$  (0.3579) y  $\hat{LB}_{z,22} = 21.9300$  (0.4643) no rechazan la hipótesis nula de ausencia de autocorrelación en los residuos estandarizados. Lo mismo sucede con los estadísticos  $\hat{LB}_{z^2,10} = 14.1000$  (0.1684) y  $\hat{LB}_{z^2,22} = 21.2000$  (0.5087) aplicados al cuadrado de los residuos estandarizados.

A la hora de estudiar el efecto apalancamiento, no se verifica la existencia de efectos individuales en el signo  $\hat{t}_{signo} = 0.0656$  (0.9477) y las magnitudes negativas  $\hat{t}_{tam-} = 1.2800$  (0.2007). Las magnitudes positivas  $\hat{t}_{tam+} = 2.0010$  (0.0456) presentan un efecto significativo pero la prueba conjunta  $\hat{F} = 6.3860$  (0.0942) sugiere en sentido contrario.

En resumen, el modelo logra capturar todo el efecto de la autocorrelación en los retornos y la heterocedasticidad condicional. En cambio, no ajusta la asimetría y las colas largas en las perturbaciones. Los datos no requieren la incorporación del efecto apalancamiento en el modelo.

Se proponen diversas alternativas para resolver las deficiencias relevadas. El exceso de curtosis sugiere emplear la distribución generalizada del error y t de Student. Dado que la asimetría es moderada, se presta especial atención a las densidades asimétricas. También se ajustan modelos con una especificación

asimétrica para la función de volatilidad.

Los criterios de información de Akaike y Bayesiano seleccionan respectivamente a los modelos eGARCH y GARCH con distribución generalizada del error en su parametrización asimétrica. El segundo criterio selecciona una ecuación más simple para la volatilidad producto de la mayor penalización que aplica al parámetro adicional del eGARCH. En todos los casos, la prueba de bondad de ajuste  $\chi^2$  rechaza la hipótesis nula sobre la distribución supuesta.

Si bien estos modelos resuelven algunas de las limitaciones identificadas en el modelo base, la ganancia en poder predictivo resulta pequeña y muy específica. Los estadísticos direccionales y el exceso al VaR para el 1 % resultan muy similar. Por su parte, el modelo GARCH aporta una leve mejora en las medidas de error medio.

#### 5.4.10. TECO2

Los residuos estandarizados del modelo base muestran prácticamente la inexistencia de asimetría ( $\hat{s} = 0.0835$ ) y moderado exceso de curtosis ( $\hat{k} = 3.9280$ ). Los estadísticos de Jarque-Bera  $\hat{J}B = 65.2500$  ( $< 0.0001$ ) y bondad de ajuste  $\chi^2$  de Pearson  $\hat{x}^2 = 135.5100$  ( $< 0.0001$ ) rechazan la hipótesis nula de normalidad en los residuos. Los estadísticos de Ljung-Box para los primeros 10 y 22 rezagos  $\hat{L}B_{z,10} = 12.5700$  (0.2489) y  $\hat{L}B_{z,22} = 21.6500$  (0.4809) no rechazan la hipótesis nula de ausencia de autocorrelación en los residuos estandarizados. Lo mismo sucede con los estadísticos  $\hat{L}B_{z^2,10} = 13.0790$  (0.2193) y  $\hat{L}B_{z^2,22} = 24.0800$  (0.3430) aplicados al cuadrado de los residuos estandarizados.

A la hora de estudiar el efecto apalancamiento, no se verifica la existencia de efectos individuales en las magnitudes positivas  $\hat{t}_{tam+} = 0.5380$  (0.5906). No obstante, el signo  $\hat{t}_{signo} = 2.2970$  (0.0217), las magnitudes negativas  $\hat{t}_{tam-} = 3.6310$  (0.0003) y la prueba conjunta  $\hat{F} = 13.5290$  (0.0036) concluyen en sentido opuesto.

En resumen, el modelo logra capturar todo el efecto de la autocorrelación en los retornos y la heterocedasticidad condicional. En cambio, no ajusta la asimetría y las colas largas en las perturbaciones. Los datos requieren la incorporación del efecto apalancamiento en el modelo.

Se proponen diversas alternativas para resolver las deficiencias relevadas. El exceso de curtosis sugiere emplear la distribución generalizada del error. La asimetría es leve pero podría estar asociada al efecto apalancamiento, con lo cual se prueban las densidades simétricas y asimétricas y además se hace especial énfasis en aquellos modelos con ecuaciones no lineales para la volatilidad.

Los criterios de información de Akaike y Bayesiano seleccionan respectivamente a los modelos eGARCH con distribución generalizada del error en su parametrización asimétrica y GARCH con igual distribución y parametrización simétrica. El segundo criterio selecciona una ecuación más simple para la volatilidad producto de la mayor penalización que aplica a los parámetros adicionales del eGARCH y la asimetría en la función de densidad. En todos los casos, la prueba de bondad de ajuste  $\chi^2$  rechaza la hipótesis nula sobre la distribución supuesta.

Si bien estos modelos tampoco cumplen con la totalidad de sus supuestos, logran una mejor aproximación respecto del modelo base y además presentan un mayor poder predictivo. Aunque los estadísticos direccionales resultan similares, las medidas de error medio de pronóstico evidencian mejoras para el modelo eGARCH: el  $R^2$  de Mincer-Zarnowitz mejora desde 0.5655 hacia 0.6699, y la Raíz del Error Cuadrático Medio disminuye desde 0.0051 hacia 0.0045. El modelo GARCH se asimila al base.

Se verifica además que la elección de la función de densidad afecta directamente la amplitud de los intervalos para la media, lo cual se refleja en una gran mejora en la cantidad de excesos al VaR para el 1%. Para una cantidad esperada de 5 observaciones, el modelo base presenta 9, eGARCH 7 y GARCH 5. Es decir, los pronósticos del eGARCH son superiores en términos de error medio mientras que aquellos del GARCH son más precisos en términos de intervalos.

#### 5.4.11. TS

Los residuos estandarizados del modelo base no muestran asimetría ( $\hat{s} = -0.0303$ ) y marcado exceso de curtosis ( $\hat{k} = 3.5130$ ). Los estadísticos de Jarque-Bera  $\hat{JB} = 19.6000$  ( $< 0.0001$ ) y bondad de ajuste  $\chi^2$  de Pearson  $\hat{x}^2 = 79.2900$  (0.0040) rechazan la hipótesis nula de normalidad en los residuos. Los estadísticos de

Ljung-Box para los primeros 10 y 22 rezagos  $\hat{LB}_{z,10} = 8.7960$  (0.5516) y  $\hat{LB}_{z,22} = 17.7700$  (0.7194) no rechazan la hipótesis nula de ausencia de autocorrelación en los residuos estandarizados. Lo mismo sucede con los estadísticos  $\hat{LB}_{z^2,10} = 12.2900$  (0.2662) y  $\hat{LB}_{z^2,22} = 18.9100$  (0.6509) aplicados al cuadrado de los residuos estandarizados.

A la hora de estudiar el efecto apalancamiento, no se verifica la existencia de efectos individuales en el signo  $\hat{t}_{signo} = 1.2680$  (0.2051), las magnitudes negativas  $\hat{t}_{tam-} = 0.9279$  (0.3536) y las magnitudes positivas  $\hat{t}_{tam+} = 0.3028$  (0.7621). La prueba conjunta  $\hat{F} = 2.9830$  (0.3942) permite concluir en un mismo sentido.

En resumen, el modelo logra capturar todo el efecto de la autocorrelación en los retornos y la heterocedasticidad condicional. En cambio, no ajusta las colas largas en las perturbaciones. Los datos no requieren la incorporación del efecto apalancamiento en el modelo.

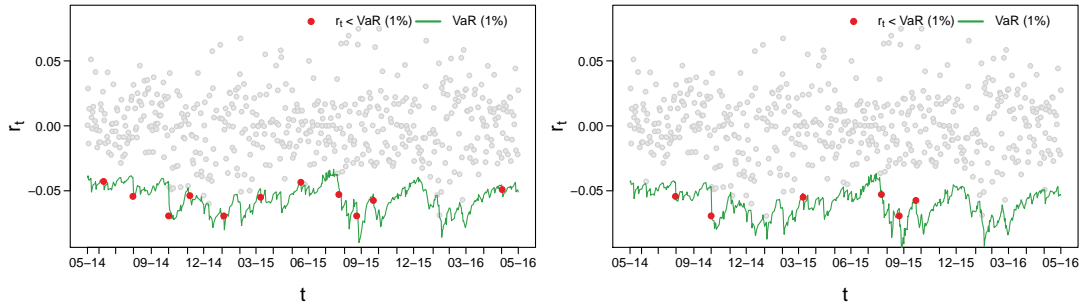
Se proponen diversas alternativas para resolver las deficiencias relevadas. El fuerte exceso de curtosis sugiere emplear la distribución generalizada del error y t de Student. Aunque a priori no parece necesario, no se descartan las densidades asimétricas y se ajustan modelos con una especificación asimétrica para la función de volatilidad.

Los criterios de información de Akaike y Bayesiano seleccionan el modelo GARCH con distribución generalizada del error. La prueba de bondad de ajuste  $\chi^2$  no rechaza la hipótesis nula sobre la distribución supuesta.

Si bien estos modelos resuelven algunas de las limitaciones identificadas en el modelo base, no necesariamente presentan un mayor poder predictivo. Los estadísticos direccionales resultan prácticamente idénticos. Similarmente, las medidas de error medio no evidencian mejoras.

No obstante, se verifica que la elección de la función de densidad afecta directamente la amplitud de los intervalos para la media, lo cual se refleja en una gran mejora en la cantidad de excesos al VaR para el 1%. Según se muestra en la [Figura 5.5](#), para una cantidad esperada de 5 observaciones, el modelo base presenta 11 y el propuesto 6. Es decir, la nueva función de densidad mejora única la amplitud del intervalo de pronósticos.





**Figura 5.5:** Retornos observados y *Value At Risk* al 1% predicho en el momento anterior (TS). En rojo, aquellos retornos que exceden el límite estimado. Izquierda: Modelo base con error gaussiano. Derecha: Modelo alternativo con Distribución Generalizada del Error. Elaboración propia.

### 5.4.12. YPFD

Los residuos estandarizados del modelo base muestran una asimetría negativa ( $\hat{s} = -0.1484$ ) y muy fuerte exceso de curtosis ( $\hat{k} = 4.9750$ ). Los estadísticos de Jarque-Bera  $\hat{J}B = 285.4000$  ( $< 0.0001$ ) y bondad de ajuste  $\chi^2$  de Pearson  $\hat{\chi}^2 = 164.7700$  ( $< 0.0001$ ) rechazan la hipótesis nula de normalidad en los residuos. Los estadísticos de Ljung-Box para los primeros 10 y 22 rezagos  $\hat{L}B_{z,10} = 6.2520$  (0.7936) y  $\hat{L}B_{z,22} = 18.2200$  (0.6927) no rechazan la hipótesis nula de ausencia de autocorrelación en los residuos estandarizados. Lo mismo sucede con los estadísticos  $\hat{L}B_{z^2,10} = 6.3840$  (0.7820) y  $\hat{L}B_{z^2,22} = 22.0000$  (0.4597) aplicados al cuadrado de los residuos estandarizados.

A la hora de estudiar el efecto apalancamiento, no se verifica la existencia de efectos individuales en el signo  $\hat{t}_{signo} = 0.4903$  (0.6240), las magnitudes negativas  $\hat{t}_{tam-} = 1.6576$ (0.0976) y las magnitudes positivas  $\hat{t}_{tam+} = 0.4217$ (0.6733). La prueba conjunta  $\hat{F} = 5.0438$  (0.1686) permite concluir en un mismo sentido.

En resumen, el modelo logra capturar todo el efecto de la autocorrelación en los retornos y la heterocedasticidad condicional. En cambio, no ajusta las colas largas en las perturbaciones. Los datos no requieren la incorporación del efecto apalancamiento en el modelo.

Se proponen diversas alternativas para resolver las deficiencias relevadas. El fuerte exceso de curtosis sugiere emplear la distribución generalizada del error y *t* de Student. Dado que la asimetría es leve, se prueban las densidades simétricas y

asimétricas. También se ajustan modelos con una especificación asimétrica para la función de volatilidad.

Los criterios de información de Akaike y Bayesiano seleccionan el modelo eGARCH con distribución generalizada del error. La prueba de bondad de ajuste  $\chi^2$  rechaza la hipótesis nula sobre la distribución supuesta.

Si bien estos modelos resuelven algunas de las limitaciones identificadas en el modelo base, el efecto en el poder predictivo es mixto. El estadístico direccional de aciertos en los incrementos de la volatilidad parece mejorar levemente, aunque los restantes son similares. Las medidas de error medio de pronóstico empeoran, y la cantidad de excesos al VaR para el 1% muestra una sobrestimación de los intervalos de predicción.

Acción	APBR	BMA	COME	EDN	ERAR	FRAN	GGAL	MERVAL	PAMP	TECO2	TS	YFPD
<b>Panel A: Diagnóstico de residuos para GARCH(1, 1) con distribución gaussiana (modelo base)</b>												
Asimetría	No	Débil	Moderado	Moderado	Débil	Débil	Débil	Débil	Moderado	No	No	Débil
Colas pesadas	Moderado	Moderado	Fuerte	Fuerte	Fuerte	Moderado	Moderado	Moderado	Moderado	Moderado	Débil	Fuerte
Rechazar distribución adecuada	Mixto	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí
Rechazar ausencia de autocorrelación	No	No	Sí	No	No	No	No	No	No	No	No	No
Rechazar ausencia de heterocedasticidad cond.	No	No	No	No	No	No	No	No	No	No	No	No
Rechazar ausencia de efecto signo	Sí	No	No	No	No	No	No	No	No	No	No	No
Rechazar ausencia de efecto magnitud positiva	No	No	No	No	No	No	No	No	Sí	No	No	No
Rechazar ausencia de efecto magnitud negativa	No	No	No	No	No	No	No	No	No	Sí	No	No
Rechazar ausencia de efecto conjunto	No	No	No	No	No	No	No	No	No	Sí	No	No
<b>Panel B: Diagnóstico de residuos para el modelo seleccionado</b>												
Modelo seleccionado	eGARCH	GARCH	GARCH	GARCH	GARCH	GARCH	GARCH	GARCH	GARCH	GARCH	GARCH	eGARCH
	STD	GED	sGED	sGED	sGED	sGED	sGED	GED	sGED	GED	GED	GED
Rechazar distribución adecuada	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	Sí	No	Sí
Rechazar ausencia de autocorrelación	No	No	Sí	No	No	No	No	No	No	No	No	No
Rechazar ausencia de heterocedasticidad cond.	No	No	No	No	No	No	No	No	No	No	No	No
Rechazar ausencia de efecto signo	No	No	No	No	No	No	No	No	No	No	No	No
Rechazar ausencia de efecto magnitud positiva	No	No	No	No	No	No	No	No	No	No	No	No
Rechazar ausencia de efecto magnitud negativa	No	No	No	No	No	No	No	No	No	No	No	No
Rechazar ausencia de efecto conjunto	No	No	No	No	No	No	No	No	No	No	No	No
<b>Panel C: Evaluación de pronósticos para el modelo preferido</b>												
Direccional	Similar	Similar	Mejor (fuerte)	Similar	Similar	Similar	Similar	Similar	Similar	Similar	Similar	Similar
Media	Peor (débil)	Similar	Mejor (fuerte)	Similar	Similar	Similar	Similar	Similar	Mejor (débil)	Mejor (débil)	Similar	Peor (débil)
VaR	Peor (fuerte)	Mejor (fuerte)	Mejor (fuerte)	Similar	Similar	Mejor (débil)	Mejor (fuerte)	Mejor (fuerte)	Similar	Mejor (fuerte)	Mejor (fuerte)	Peor (débil)

**Cuadro 5.2:** Resumen del proceso de diagnóstico de residuos, selección de modelos y evaluación de pronósticos. El [Anexo B](#) recopila todos los estadísticos empleados para la confección del presente Cuadro. **Panel A** Describe las características observadas en los residuos del modelo base  $ARMA(1, 1) - GARCH(1, 1)$ . **Panel B** Resume los fenómenos observados en los residuos del modelo seleccionado. **Panel C** Compara los pronósticos del modelo seleccionado respecto del base. Elaboración propia.

# Capítulo 6

## Consideraciones finales

Más allá de las características observadas en cada serie en particular, vale la pena buscar generalizaciones del análisis realizado para los datos bajo estudio.

### Del diagnósticos de residuos

En términos generales, la hipótesis de normalidad en los residuos del modelo base no se cumple. De las doce series analizadas, los residuos del modelo base para nueve acciones muestran una distribución asimétrica. Sólo tres de ellas observan un nivel de asimetría suficientemente importante para cuestionar el supuesto distribucional. Por su parte, todas las series estudiadas son leptocúrticas. Más aún, en once casos el exceso de curtosis es demasiado marcado para considerar una aproximación gaussiana.

El modelo base captura satisfactoriamente el efecto de la autocorrelación lineal en los retornos y el cuadrado de las perturbaciones. Sólo en un caso los residuos muestran autocorrelación lineal: esta limitación puede imputarse al modelo para la media y excede el alcance de este trabajo. De hecho, la ecuación para la media podría enriquecerse con variables exógenas. Es importante destacar que la especificación  $GARCH(1, 1)$  resulta suficiente para modelar la heterocedasticidad condicional.

El efecto apalancamiento, muy difundido en los trabajos de investigación para otros mercados, es observado sólo en circunstancias muy particulares. Tres casos sugieren la existencia de algún efecto individual, pero sólo uno presenta

evidencia para un efecto conjunto.

En resumen, la leptocurtosis se impone como la característica más determinante y se constituye como la principal falla al supuesto de densidad gaussiana. La asimetría juega un rol más acotado y sólo atenta contra la aproximación normal en ciertos casos puntuales.

Los criterios de información priorizan los modelos GARCH en diez casos y eGARCH en los dos casos restantes, uno de ellos asociado al efecto apalancamiento. Las densidades que acompañan las especificaciones son la distribución generalizada del error en sus versiones asimétrica y simétrica y la distribución *t* de Student en seis, cinco y una oportunidad respectivamente. Es decir, sólo en la mitad de los casos la asimetría resulta ser lo suficientemente marcada para compensar la pérdida de grados de libertad. Salvo por una excepción, la distribución seleccionada no ajusta los residuos pero ofrece una gran mejora en la aproximación respecto de la función de densidad gaussiana.

### **Del pronóstico de la volatilidad**

La predicción fuera de la muestra sólo mejoró en términos direccionales en un caso, mientras que los restantes modelos se mostraron muy similares para predecir tanto subas como bajas en el nivel de volatilidad. Esta única mejora se observa justamente en aquél caso que presenta mayor nivel de asimetría: si bien un caso no es suficiente para concluir sobre generalidades, es un indicio que estos modelos permiten mejorar la predicción de la dirección de la volatilidad cuando las acciones muestran retornos asimétricos.

A la hora de pronosticar el valor medio de la volatilidad un período hacia adelante, ocho casos muestran un desempeño similar. COME y PAMP incrementan su precisión, destacándose especialmente la mejora que evidencia el primer caso gracias a una función de densidad que modela en simultáneo leptocurtosis y asimetría.

Los dos individuos con peor desempeño pueden atribuirse a la sobreparametrización del modelo seleccionado por los criterios de información. En el caso de YPFD, priorizan un modelo eGARCH con distribución generalizada del error cuando los retornos no muestran asimetría. Por otro lado, proponen un modelo con dis-

tribución  $t$  de Student para APBR aunque los retornos no poseen colas pesadas.

En relación a la amplitud de los intervalos para el valor esperado de los pronósticos, los modelos mejoran la cantidad de excesos al VaR en siete casos (BMA, COME, FRAN, GGAL, Merval, TECO2, TS). Salvo por FRAN, el incremento en la precisión es muy importante. Este avance es consecuencia directa de emplear una función de densidad que se adapta a colas más pesadas y, en tres casos particulares (COME, FRAN, GGAL), a la modelización explícita de la asimetría. APBR e YPFD muestran un peor desempeño en los pronósticos debido al sobreajuste mencionado anteriormente, mientras que las restantes acciones no muestran diferencias.

En resumen, un mayor ajuste dentro de la muestra no necesariamente implica una mayor capacidad de pronóstico, aunque existen ciertas mejoras que merecen ser mencionadas. Si bien los criterios de información penalizan la cantidad de parámetros, en dos casos se observaron deterioros en el desempeño predictivo de los modelos, con lo cual se destaca la importancia de tener extrema precaución con el sobreajuste.

### **Otras consideraciones**

Los criterios de información de Akaike y Bayesiano son muy útiles a la hora de seleccionar modelos pues miden el grado de ajuste al conjunto de datos observado. En la búsqueda de modelos más parsimoniosos, ofrecen diferentes penalizaciones para la cantidad de parámetros efectivamente estimados. En los casos bajo estudio, se observa que los modelos seleccionados por el criterio Bayesiano no sólo son más simples, sino que además tienen más sentido desde el punto de vista financiero. Es decir, en aquellas oportunidades donde los criterios no seleccionan un mismo modelo, el BIC se orienta en favor del más natural para la práctica de las finanzas.

No obstante, la penalización observada no siempre se mostró suficiente para evitar el sobreajuste. Los casos de APBR e YPFD son ejemplos muy claros de como el sobreajuste va en detrimento de los pronósticos. Por ello, la selección del modelo requiere de un delicado equilibrio entre la teoría estadística y financiera, así como también entre el análisis dentro y fuera de la muestra. De todas formas,

esto no debe opacar que en muchos casos se obtuvieron mejoras notables.

Finalmente, es importante resaltar que las conclusiones no son unívocas por al menos dos motivos. En primer lugar, distintas pruebas y estadísticos pueden arrojar resultados mixtos sobre una hipótesis, de forma que el análisis estadístico por sí mismo no siempre es conclusivo. En segundo lugar y más importante, la principal dificultad yace en el análisis financiero, donde diferentes agentes del mercado tienen su propia función de pérdida para evaluar los pronósticos, complejizando la selección de un modelo óptimo. Por ello, esta tesis describe los resultados de forma amplia y desde diferentes puntos de vista, permitiendo al lector tomar los resultados y adaptarlos a su función de decisión.

### **Recomendaciones para el analista financiero**

La metodología aplicada permite recopilar pequeñas recomendaciones para agilizar y facilitar el estudio de las series de tiempo financieras. El analista debe prestar atención a las decisiones que hacen al preprocesamiento de los datos, en especial al tratamiento de los valores extremos. A la hora de especificar el modelo, no resulta necesario incrementar el orden más allá de  $GARCH(1, 1)$ . El foco debe situarse en la selección de la función de densidad. Si bien la distribución permite ajustar leptocurtosis y asimetría en simultáneo, en la práctica la primera característica tiene mayor peso. Aunque la elección de una ecuación no lineal para la volatilidad no debe ser minimizada, tampoco resulta prioritario.

El sobreajuste es el principal riesgo a la hora de analizar los datos. Los criterios de información resultan guías insuficientes para seleccionar modelos que mejoren la capacidad de pronóstico. La principal mejora se observa en la amplitud de los intervalos de pronóstico del retorno. Si el interés yace principalmente en obtener pronósticos puntuales, se sugiere evaluar otras estrategias como ser modelos alternativos o la incorporación de mayor información (por ejemplo, a través de regresores externos).

### **Futuras investigaciones**

Existen diversas líneas de trabajo para futuras investigaciones que busquen profundizar en la adecuación de los modelos estadísticos a la compleja teoría

y práctica financiera. Una primera alternativa es replicar la metodología aquí desarrollada a otras series de tiempo, como ser el rendimiento de los activos de renta fija, las monedas o las tasas de interés. En segunda instancia, podría evaluarse el comportamiento de los modelos propuestos en mercados de otros países, similares y diferentes, a fin de identificar paralelismos y contrapuntos. Tercero, sería de interés confirmar y complementar las conclusiones aquí presentadas mediante estudios de simulación que permitan aislar los efectos de la heterocedasticidad de posibles factores que contaminen los datos reales. Por último, aportaría gran valor analizar este mismo conjunto de datos reales mediante otras representaciones matemáticas, incluyendo la mezcla de normales (Haas *et al.*, 2004a) o modelos con estados ocultos cuya transición depende de una cadena de Markov (Haas *et al.*, 2004b).



# Bibliografía

- Aggarwal, R., Inclan, C., y Leal, R. (1999). Volatility in emerging stock markets. *Journal of Financial and Quantitative Analysis*, 34(01):33–55.
- Akgiray, V. (1989). Conditional heteroscedasticity in time series of stock returns: Evidence and forecasts. *Journal of business*, pp. 55–80.
- Andersen, T. G. y Bollerslev, T. (1998). Answering the skeptics: Yes, standard volatility models do provide accurate forecasts. *International economic review*, pp. 885–905.
- Andersen, T. G., Bollerslev, T., Diebold, F. X., y Labys, P. (2003). Modeling and forecasting realized volatility. *Econometrica*, 71(2):579–625.
- Andersen, T. G., Bollerslev, T., y Meddahi, N. (2005). Correcting the errors: Volatility forecast evaluation using high-frequency data and realized volatilities. *Econometrica*, 73(1):279–296.
- Andersen, T. G., Davis, R. A., Kreiss, J.-P., y Mikosch, T. V. (2009). *Handbook of financial time series*. Springer Science & Business Media.
- Baillie, R. T. y Bollerslev, T. (1992). Prediction in dynamic models with time-dependent conditional variances. *Journal of Econometrics*, 52(1-2):91–113.
- Berndt, E. R., Hall, B. H., Hall, R. E., y Hausman, J. A. (1974). Estimation and inference in nonlinear structural models. En *Annals of Economic and Social Measurement, Volume 3, number 4*, pp. 653–665. NBER.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of econometrics*, 31(3):307–327.

- Bollerslev, T. (1987). A conditionally heteroskedastic time series model for speculative prices and rates of return. *The review of economics and statistics*, pp. 542–547.
- Bollerslev, T. y Ghysels, E. (1996). Periodic autoregressive conditional heteroscedasticity. *Journal of Business & Economic Statistics*, 14(2):139–151.
- Bollerslev, T. y Wooldridge, J. M. (1992). Quasi-maximum likelihood estimation and inference in dynamic models with time-varying covariances. *Econometric reviews*, 11(2):143–172.
- Box, G. E. y Cox, D. R. (1964). An analysis of transformations. *Journal of the Royal Statistical Society. Series B (Methodological)*, pp. 211–252.
- Brandt, M. W. y Diebold, F. X. (2003). A no-arbitrage approach to range-based estimation of return covariances and correlations. Technical report, National Bureau of Economic Research.
- Brandt, M. W. y Kinlay, J. (2005). Estimating historical volatility. *Research Article, Investment Analytics*.
- Brooks, C. (2008). *Introduction econometrics for finance*. Cambridge: University Press, UK.
- Brooks, C., Burke, S. P., y Persaud, G. (2001). Benchmarks and the accuracy of garch model estimation. *International Journal of Forecasting*, 17(1):45–56.
- Campbell, J. Y., Lo, A. W.-C., y MacKinlay, A. C. (1997). *The econometrics of financial markets*, volumen 2. princeton University press Princeton, NJ.
- Casella, G. y Berger, R. L. (2002). *Statistical inference*, volumen 2. Duxbury Pacific Grove, CA.
- Cont, R. (2001). Empirical properties of asset returns: stylized facts and statistical issues. *Quantitative Finance*, 1:223–236.

- Daniélsson, J. (2011). *Financial risk forecasting: the theory and practice of forecasting market risk with implementation in R and Matlab*, volumen 588. John Wiley & Sons.
- Darolles, S., Florens, J.-P., y Gouriéroux, C. (1999). Kernel based nonlinear canonical analysis. Technical report.
- Diebold, F. X. (2012). Comparing predictive accuracy, twenty years later: A personal perspective on the use and abuse of diebold-mariano tests. Working Paper 18391, National Bureau of Economic Research.
- Diebold, F. X. y Mariano, R. S. (1995). Comparing predictive accuracy. *Journal of Business & Economic Statistics*, 13(3).
- Ding, Z., Granger, C. W., y Engle, R. F. (1993). A long memory property of stock market returns and a new model. *Journal of empirical finance*, 1(1):83–106.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of united kingdom inflation. *Econometrica: Journal of the Econometric Society*, pp. 987–1007.
- Engle, R. F. y Ng, V. K. (1993). Measuring and testing the impact of news on volatility. *The journal of finance*, 48(5):1749–1778.
- Engle, R. F. y Patton, A. J. (2001). What good is a volatility model. *Quantitative finance*, 1(2):237–245.
- Fernández, C. y Steel, M. F. (1998). On bayesian modeling of fat tails and skewness. *Journal of the American Statistical Association*, 93(441):359–371.
- Fiorentini, G., Calzolari, G., y Panattoni, L. (1996). Analytic derivatives and the computation of garch estimates. *Journal of Applied Econometrics*, 11(4):399–417.
- Franke, J., Härdle, W. K., y Hafner, C. M. (2004). *Statistics of financial markets*, volumen 2. Springer.

- Franses, P. H., van Dijk, D., y Opschoor, A. (2014). *Time series models for business and economic forecasting*. Cambridge university press, 2 edición.
- Garman, M. B. y Klass, M. J. (1980). On the estimation of security price volatilities from historical data. *Journal of business*, pp. 67–78.
- Ghalanos, A. (2015). *rugarch: Univariate GARCH models*. R package version 1.3-6.
- Ghysels, E., Harvey, A. C., y Renault, E. (1996). 5 stochastic volatility. *Handbook of statistics*, 14:119–191.
- Glosten, L. R., Jagannathan, R., y Runkle, D. E. (1993). On the relation between the expected value and the volatility of the nominal excess return on stocks. *The journal of finance*, 48(5):1779–1801.
- Granger, C. W. y Ding, Z. (1994). Stylized facts on the temporal and distributional properties of daily data from speculative markets. *UCSD Department of Economics Discussion Paper*, pp. 94–19.
- Haas, M., Mittnik, S., y Paoletta, M. S. (2004a). Mixed normal conditional heteroskedasticity. *Journal of Financial Econometrics*, 2(2):211–250.
- Haas, M., Mittnik, S., y Paoletta, M. S. (2004b). A new approach to markov-switching garch models. *Journal of Financial Econometrics*, 2(4):493–530.
- Hamilton, J. D. (1994). *Time series analysis*, volumen 2. Princeton university press Princeton.
- Hansen, L. P. y Hodrick, R. J. (1980). Forward exchange rates as optimal predictors of future spot rates: An econometric analysis. *The Journal of Political Economy*, pp. 829–853.
- Hansen, P. R. y Lunde, A. (2006). Consistent ranking of volatility models. *Journal of Econometrics*, 131(1):97–121.
- Higgins, M. L. y Bera, A. K. (1992). A class of nonlinear arch models. *International Economic Review*, pp. 137–158.

- Hsieh, D. A. (1989). Modeling heteroscedasticity in daily foreign-exchange rates. *Journal of Business & Economic Statistics*, 7(3):307–317.
- Jackman, S. (2009). *Bayesian analysis for the social sciences*, volumen 846. John Wiley & Sons.
- Jorion, P. (1988). On jump processes in the foreign exchange and stock markets. *Review of Financial Studies*, 1(4):427–445.
- Kenney, J. F. J. F. y Keeping, E. S. (1951). Mathematics of statistics; part two. Technical report.
- Lai, T. L. y Xing, H. (2008). *Statistical models and methods for financial markets*. Springer.
- Larsen, P. T. (2007). Goldman pays the price of being big. *Financial Times*, 13:3.
- Liu, D. C. y Nocedal, J. (1989). On the limited memory bfgs method for large scale optimization. *Mathematical programming*, 45(1-3):503–528.
- Mandelbrot, B. B. (1971). When can price be arbitrated efficiently? a limit to the validity of the random walk and martingale models. *The Review of Economics and Statistics*, pp. 225–236.
- McCullough, B. y Renfro, C. G. (1998). Benchmarks and software standards: A case study of garch procedures. *Journal of Economic and Social Measurement*, 25(2):59–71.
- Meddahi, N. (2001). A theoretical comparison between integrated and realized volatilities.
- Mincer, J. A. y Zarnowitz, V. (1969). The evaluation of economic forecasts. En *Economic forecasts and expectations: Analysis of forecasting behavior and performance*, pp. 3–46. NBER.
- Nelson, D. B. (1991). Conditional heteroskedasticity in asset returns: A new approach. *Econometrica: Journal of the Econometric Society*, pp. 347–370.

- Pagan, A. R. y Schwert, G. W. (1990). Alternative models for conditional stock volatility. *Journal of econometrics*, 45(1):267–290.
- Parkinson, M. (1980). The extreme value method for estimating the variance of the rate of return. *Journal of Business*, pp. 61–65.
- Patton, A. J. (2011). Volatility forecast comparison using imperfect volatility proxies. *Journal of Econometrics*, 160(1):246–256.
- Poon, S.-H. (2005). *A practical guide to forecasting financial market volatility*. John Wiley & Sons.
- Posedel, P. (2005). Properties and estimation of garch (1, 1) model. *Metodoloski zvezki*, 2(2):243–257.
- R Core Team (2016). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria.
- Rabemananjara, R. y Zakoian, J.-M. (1993). Threshold arch models and asymmetries in volatility. *Journal of Applied Econometrics*, 8(1):31–49.
- Rogers, L. C., Satchell, S. E., y Yoon, Y. (1994). Estimating the volatility of stock prices: a comparison of methods that use high and low prices. *Applied Financial Economics*, 4(3):241–247.
- Rogers, L. C. G. y Satchell, S. E. (1991). Estimating variance from high, low and closing prices. *The Annals of Applied Probability*, pp. 504–512.
- Ruppert, D. (2004). *Statistics and finance: an introduction*. Springer Science & Business Media.
- Sheather, S. J. y Jones, M. C. (1991). A reliable data-based bandwidth selection method for kernel density estimation. *Journal of the Royal Statistical Society. Series B (Methodological)*, pp. 683–690.
- Shephard, N. (1996). Statistical aspects of arch and stochastic volatility. *Mono-graphs on Statistics and Applied Probability*, 65:1–68.

- Sinclair, E. (2013). *Volatility trading*. John Wiley & Sons.
- Taylor, S. (1986). *Modeling financial time series*. Wiley, Chichester.
- Taylor, S. J. (1994). Modeling stochastic volatility: A review and comparative study. *Mathematical finance*, 4(2):183–204.
- Taylor, S. J. (2005). *Asset price dynamics, volatility, and prediction*. Princeton university press.
- Teräsvirta, T. y Zhao, Z. (2011). Stylized facts of return series, robust estimates and three popular models of volatility. *Applied financial economics*, 21(1-2):67–94.
- Tsay, R. S. (2010). *Analysis of financial time series*. John Wiley & Sons, 3 edición.
- Turner, A. L. y Weigel, E. J. (1992). Daily stock market volatility: 1928–1989. *Management Science*, 38(11):1586–1609.
- Venter, J. H. y de Jongh, P. J. (2002). Risk estimation using the normal inverse gaussian distribution. *Journal of Risk*, 4:1–24.
- Weiss, A. A. (1984). Arma models with arch errors. *Journal of Time Series Analysis*, 5(2):129–143.
- Weiss, A. A. (1986). Asymptotic theory for arch models: estimation and testing. *Econometric theory*, 2(01):107–131.
- West, K. D. (1996). Asymptotic inference about predictive ability. *Econometrica: Journal of the Econometric Society*, pp. 1067–1084.
- West, K. D. y Cho, D. (1995). The predictive ability of several models of exchange rate volatility. *Journal of econometrics*, 69(2):367–391.
- West, K. D. y McCracken, M. W. (1998). Regression-based tests of predictive ability. Working Paper 226, National Bureau of Economic Research.

- Whitehouse, K. (2007). One “quant” sees shakeout for the ages “10, 000 years”. *Wall Street Journal*, 11.
- Yang, D. y Zhang, Q. (2000). Drift-independent volatility estimation based on high, low, open, and close prices. *The Journal of Business*, 73(3):477–492.
- Zakoian, J.-M. (1994). Threshold heteroskedastic models. *Journal of Economic Dynamics and control*, 18(5):931–955.
- Zivot, E. (2009). Practical issues in the analysis of univariate garch models. En *Handbook of financial time series*, pp. 113–155. Springer.
- Zivot, E. y Wang, J. (2007). *Modeling financial time series with S-Plus®*, volumen 191. Springer Science & Business Media.

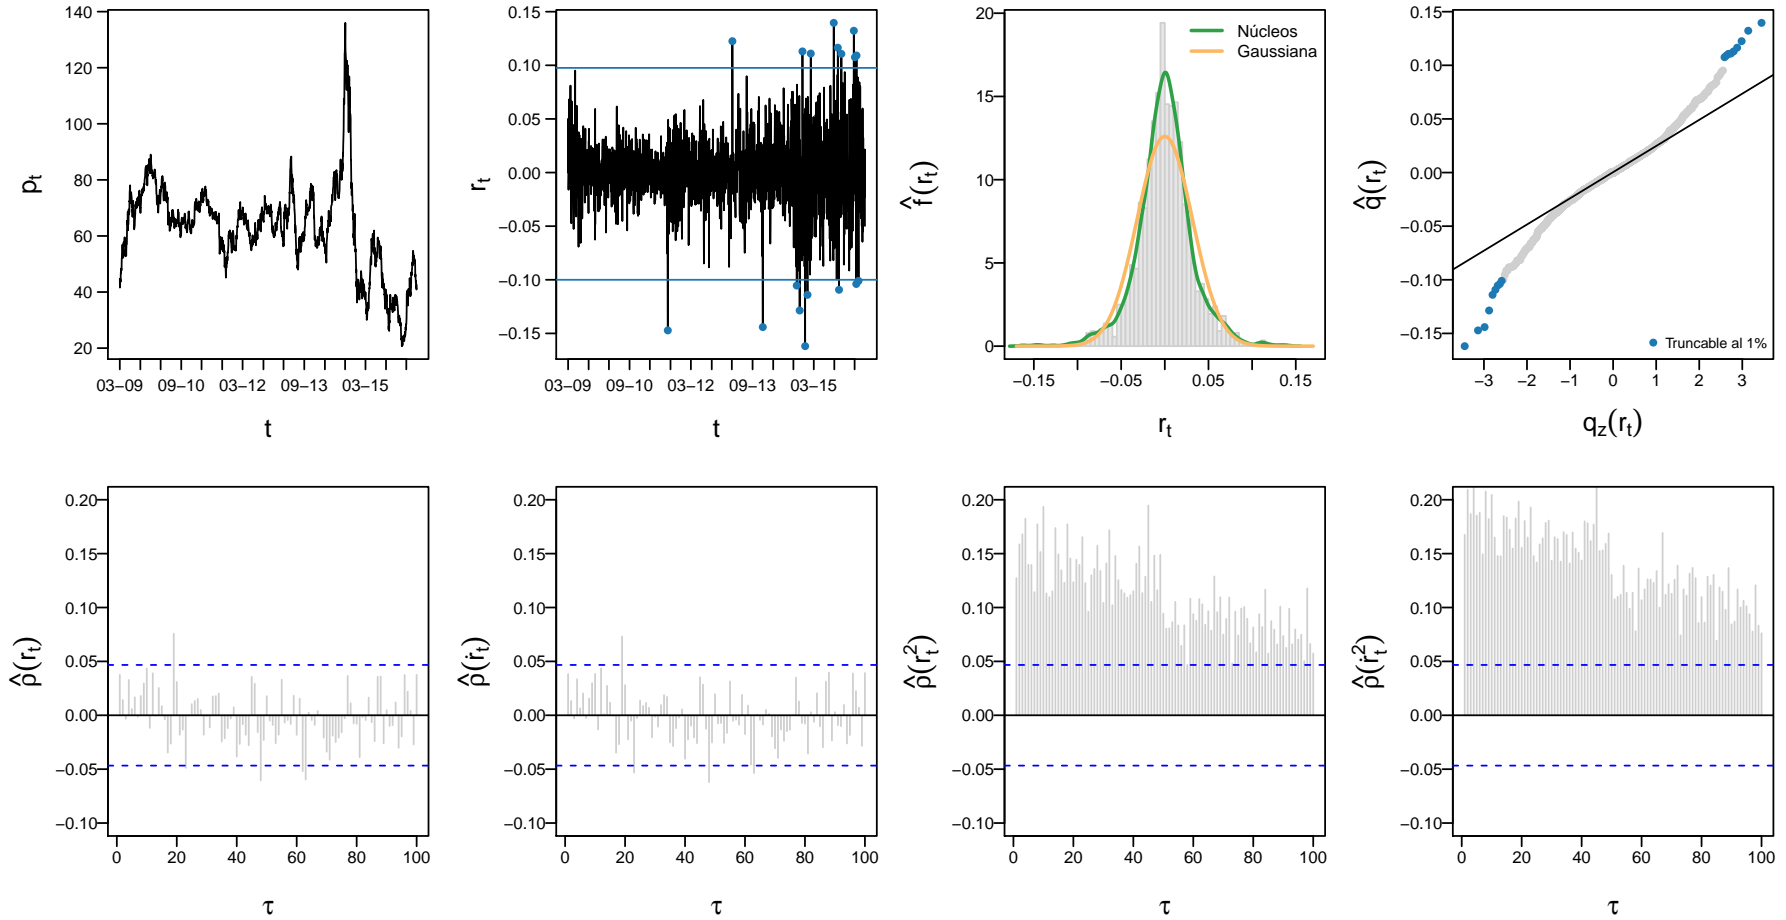


**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
Retornos (datos originales)

Estadístico	APBR	BMA	COME	EDN	ERAR	FRAN	GGAL	MERVAL	PAMP	TECO2	TS	YFPD
Comienzo	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09	02-03-09
Fin	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16	31-05-16
Observaciones	1761	1761	1758	1760	1757	1761	1761	1760	1761	1760	1761	1718
Mínimo	-0.1619	-0.1059	-0.2134	-0.2291	-0.1049	-0.1285	-0.1263	-0.1135	-0.1466	-0.1147	-0.1244	-0.3377
Máximo	0.1396	0.1677	0.2329	0.1992	0.1413	0.1372	0.1460	0.0832	0.1238	0.1095	0.1137	0.1553
Media	-0.0000	0.0019	0.0014	0.0016	0.0016	0.0022	0.0024	0.0015	0.0015	0.0014	0.0011	0.0008
Mediana	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0013	0.0000	0.0000	0.0010	0.0000
Desvío Estándar	0.0316	0.0295	0.0328	0.0359	0.0268	0.0296	0.0288	0.0206	0.0289	0.0253	0.0238	0.0310
Asimetría	-0.1028	0.2386	0.5548	0.3592	0.2445	0.0961	0.2051	-0.3439	0.1739	0.0282	-0.0392	-0.9987
Curtosis	5.2653	4.6401	7.9848	7.1949	5.1484	4.3280	4.9862	5.3144	4.7214	4.6644	4.8070	14.1385
Jarque-Bera	379.6342	214.0900	1910.2909	1328.3397	355.4116	132.1078	301.7931	427.5086	226.3033	203.3947	240.0465	9166.6304
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	10.7890	12.4498	63.7886	20.5768	46.2618	21.2437	12.6550	14.8459	16.7336	19.1612	14.3931	29.0326
p-valor	0.3742	0.2561	<0.0001	0.0242	<0.0001	0.0195	0.2436	0.1378	0.0805	0.0383	0.1558	0.0012
$r^2$ Ljung-Box (10)	436.4358	94.0130	153.3759	324.5678	107.9166	132.1049	110.2519	179.4385	232.2751	67.9719	175.1099	124.6986
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (22)	31.2265	21.0416	69.6672	37.2267	69.5103	28.8742	27.5592	37.3987	25.6903	31.3222	29.0347	50.1177
p-valor	0.0916	0.5182	<0.0001	0.0223	<0.0001	0.1485	0.1908	0.0214	0.2652	0.0897	0.1439	0.0006
$r^2$ Ljung-Box (22)	849.3547	145.4245	167.7414	443.2914	162.8177	160.3332	118.5569	213.1269	376.2944	103.8449	257.0310	134.3959
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Sesgo del signo	2.4271	1.0741	0.8920	1.1124	0.0421	0.0683	0.5076	1.6238	0.2386	2.0549	1.5584	0.3007
p-valor	0.0153	0.2829	0.3725	0.2661	0.9664	0.9455	0.6118	0.1046	0.8114	0.0400	0.1193	0.7636
Sesgo de tamaño negativo	1.6871	0.1796	0.3912	0.4712	0.4346	0.6037	0.3720	0.1487	1.1057	3.1024	1.1209	2.7661
p-valor	0.0918	0.8575	0.6957	0.6376	0.6639	0.5461	0.7099	0.8818	0.2690	0.0019	0.2625	0.0057
Sesgo de tamaño positivo	0.0164	0.9579	0.7411	0.3997	0.2387	0.3185	0.9521	0.8129	2.7917	0.4120	0.2848	0.0852
p-valor	0.9869	0.3383	0.4587	0.6894	0.8114	0.7501	0.3412	0.4164	0.0053	0.6804	0.7758	0.9321
Efecto conjunto	8.1146	1.4701	0.9133	2.7423	0.4562	0.4798	1.1376	10.5703	10.4616	9.9942	4.1708	11.5426
p-valor	0.0437	0.6892	0.8222	0.4331	0.9284	0.9233	0.7680	0.0143	0.0150	0.0186	0.2436	0.0091

**Cuadro A.1:** Estadísticos resumen para la serie de retornos (datos originales). Elaboración propia.

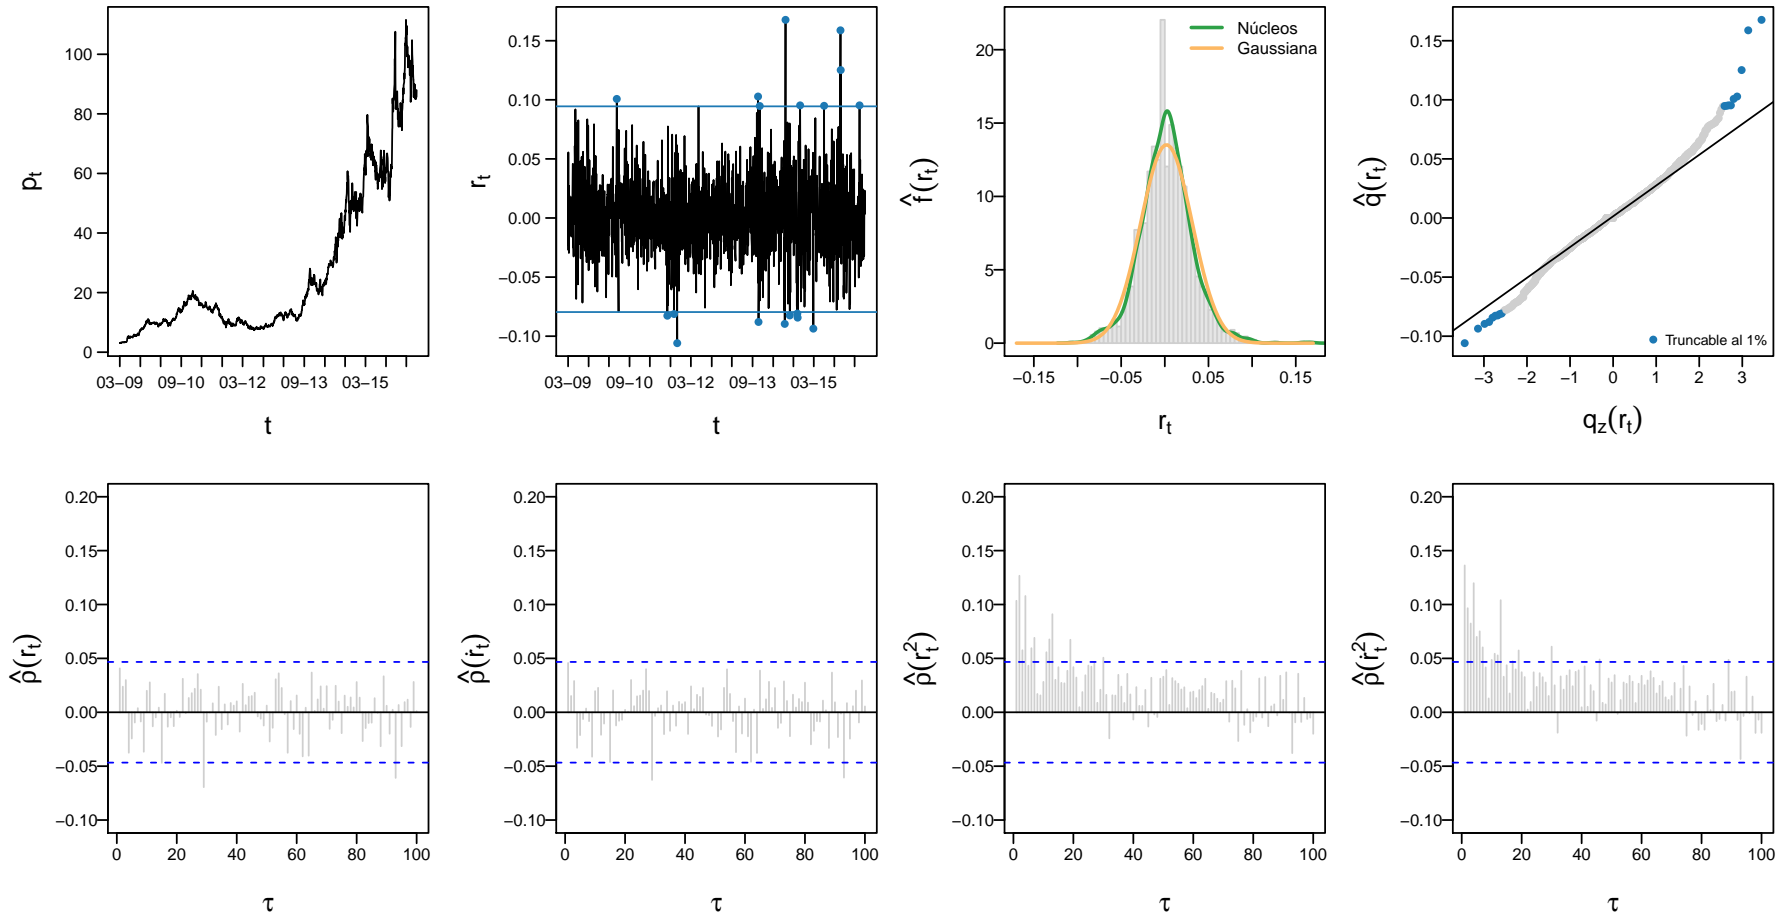
ANEXO A  
 Hechos estilizados sobre los retornos y la volatilidad  
 Retornos (APBR)



**Figura A.1:** Análisis exploratorio de APBR.

**Arriba** Primero: Serie histórica de precios. Segundo: Serie histórica del retorno logarítmico. Los puntos azules destacan aquellas observaciones que serían truncadas al 1%. Las líneas marcan el valor del cuantil. Tercero: Histograma de los retornos logarítmicos. Los parámetros de la distribución gaussiana son estimados por máxima verosimilitud en  $\hat{\mu} = -1.744E - 05$  y  $\hat{\sigma}^2 = 3.163E - 02$ . La densidad por núcleos es estimada mediante un kernel gaussiano y un ancho de ventana de  $5.327E - 03$  seleccionado por [Sheather y Jones \(1991\)](#). Cuarto: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. **Abajo** Primero: Autocorrelograma para los retornos logarítmicos (datos originales). Segundo: Autocorrelograma para los retornos logarítmicos (datos truncados al 1%). Tercero: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos originales). Cuarto: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos truncados al 1%). Elaboración propia.

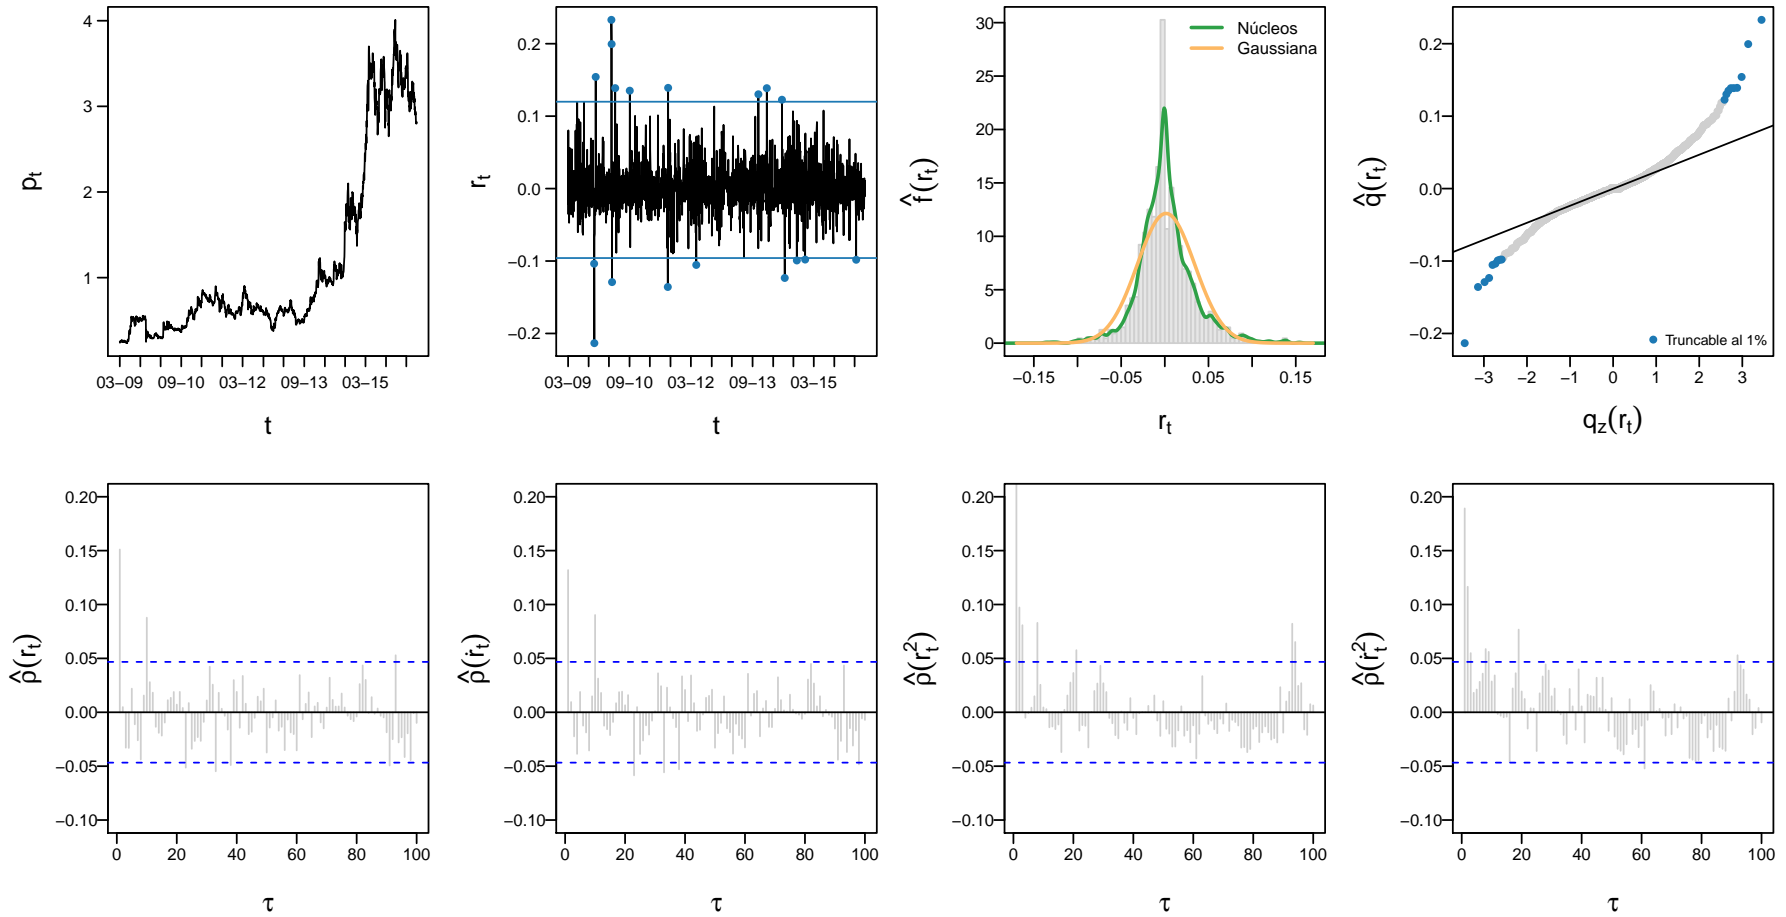
**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Retornos (BMA)



**Figura A.2:** Análisis exploratorio de BMA.

**Arriba** Primero: Serie histórica de precios. Segundo: Serie histórica del retorno logarítmico. Los puntos azules destacan aquellas observaciones que serían truncadas al 1%. Las líneas marcan el valor del cuantil. Tercero: Histograma de los retornos logarítmicos. Los parámetros de la distribución gaussiana son estimados por máxima verosimilitud en  $\hat{\mu} = 1.900E - 03$  y  $\hat{\sigma}^2 = 2.950E - 02$ . La densidad por núcleos es estimada mediante un kernel gaussiano y un ancho de ventana de  $5.698E - 03$  seleccionado por [Sheather y Jones \(1991\)](#). Cuarto: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. **Abajo** Primero: Autocorrelograma para los retornos logarítmicos (datos originales). Segundo: Autocorrelograma para los retornos logarítmicos (datos truncados al 1%). Tercero: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos originales). Cuarto: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos truncados al 1%). Elaboración propia.

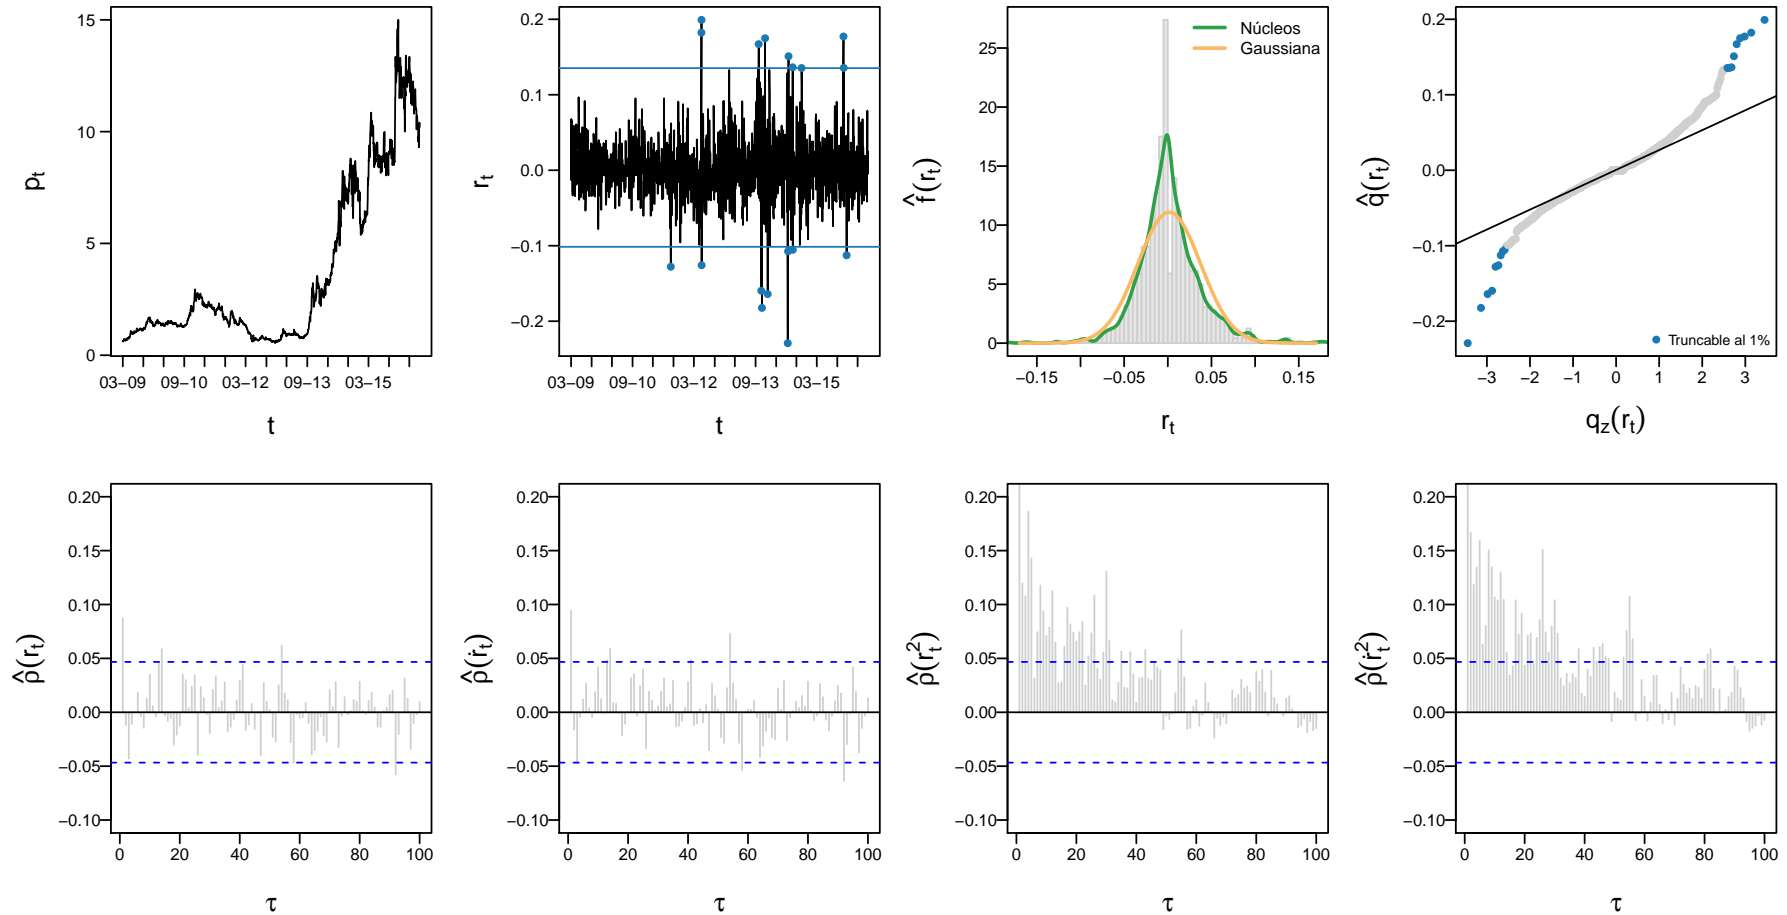
ANEXO A  
 Hechos estilizados sobre los retornos y la volatilidad  
 Retornos (COME)



**Figura A.3:** Análisis exploratorio de COME.

**Arriba** Primero: Serie histórica de precios. Segundo: Serie histórica del retorno logarítmico. Los puntos azules destacan aquellas observaciones que serían truncadas al 1%. Las líneas marcan el valor del cuantil. Tercero: Histograma de los retornos logarítmicos. Los parámetros de la distribución gaussiana son estimados por máxima verosimilitud en  $\hat{\mu} = 1.392E - 03$  y  $\hat{\sigma}^2 = 3.283E - 02$ . La densidad por núcleos es estimada mediante un kernel gaussiano y un ancho de ventana de  $3.071E - 03$  seleccionado por Sheather y Jones (1991). Cuarto: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. **Abajo** Primero: Autocorrelograma para los retornos logarítmicos (datos originales). Segundo: Autocorrelograma para los retornos logarítmicos (datos truncados al 1%). Tercero: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos originales). Cuarto: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos truncados al 1%). Elaboración propia.

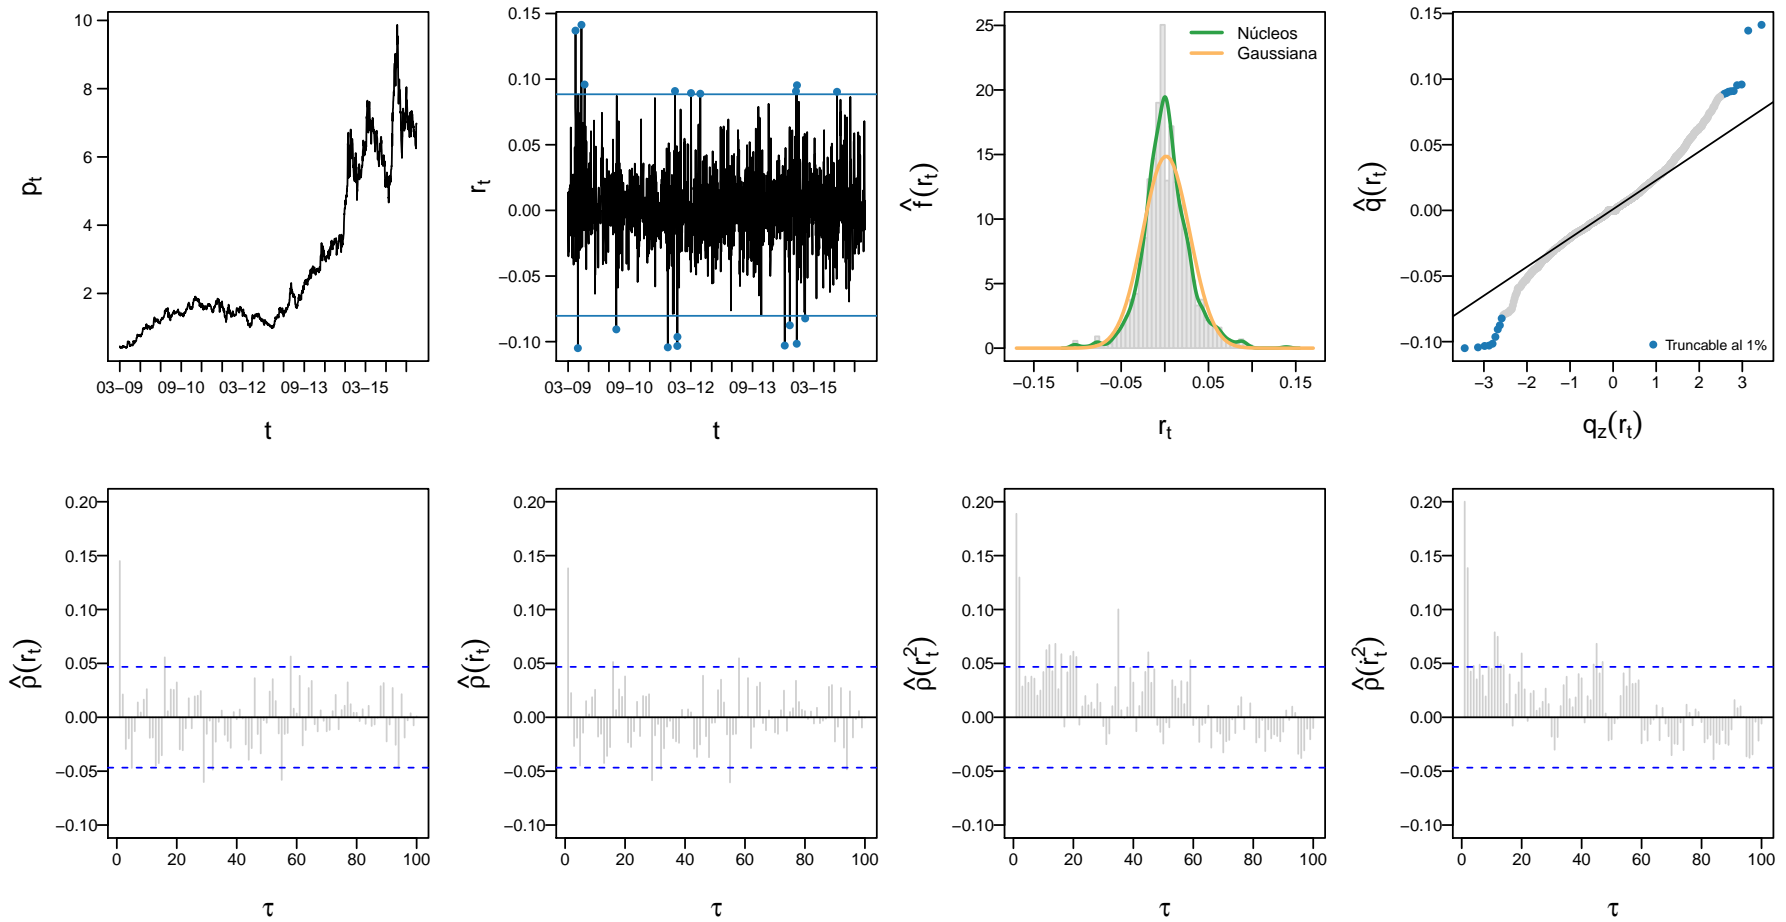
ANEXO A  
 Hechos estilizados sobre los retornos y la volatilidad  
 Retornos (EDN)



**Figura A.4:** Análisis exploratorio de EDN.

**Arriba** Primero: Serie histórica de precios. Segundo: Serie histórica del retorno logarítmico. Los puntos azules destacan aquellas observaciones que serían truncadas al 1%. Las líneas marcan el valor del cuantil. Tercero: Histograma de los retornos logarítmicos. Los parámetros de la distribución gaussiana son estimados por máxima verosimilitud en  $\hat{\mu} = 1.602E - 03$  y  $\hat{\sigma}^2 = 3.594E - 02$ . La densidad por núcleos es estimada mediante un kernel gaussiano y un ancho de ventana de  $4.233E - 03$  seleccionado por [Sheather y Jones \(1991\)](#). Cuarto: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. **Abajo** Primero: Autocorrelograma para los retornos logarítmicos (datos originales). Segundo: Autocorrelograma para los retornos logarítmicos (datos truncados al 1%). Tercero: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos originales). Cuarto: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos truncados al 1%). Elaboración propia.

ANEXO A  
 Hechos estilizados sobre los retornos y la volatilidad  
 Retornos (ERAR)



**Figura A.5:** Análisis exploratorio de ERAR.

**Arriba** Primero: Serie histórica de precios. Segundo: Serie histórica del retorno logarítmico. Los puntos azules destacan aquellas observaciones que serían truncadas al 1%. Las líneas marcan el valor del cuantil. Tercero: Histograma de los retornos logarítmicos. Los parámetros de la distribución gaussiana son estimados por máxima verosimilitud en  $\hat{\mu} = 1.560E - 03$  y  $\hat{\sigma}^2 = 2.682E - 02$ . La densidad por núcleos es estimada mediante un kernel gaussiano y un ancho de ventana de  $4.297E - 03$  seleccionado por [Sheather y Jones \(1991\)](#). Cuarto: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. **Abajo** Primero: Autocorrelograma para los retornos logarítmicos (datos originales). Segundo: Autocorrelograma para los retornos logarítmicos (datos truncados al 1%). Tercero: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos originales). Cuarto: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos truncados al 1%). Elaboración propia.

ANEXO A  
 Hechos estilizados sobre los retornos y la volatilidad  
 Retornos (FRAN)

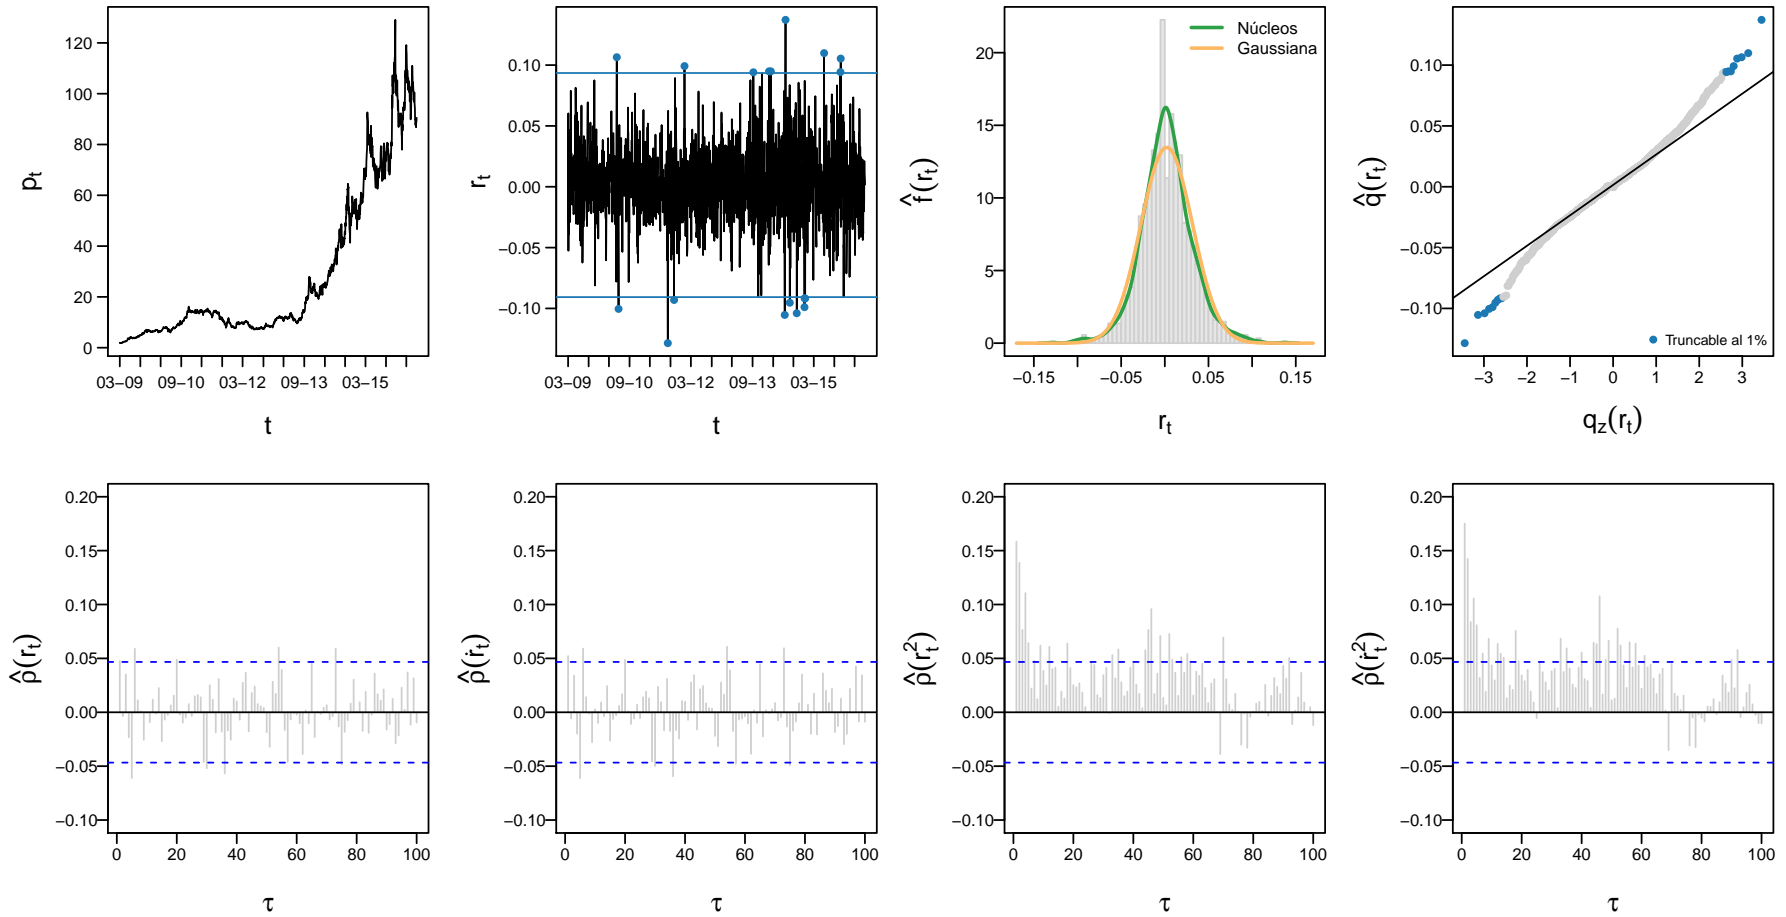
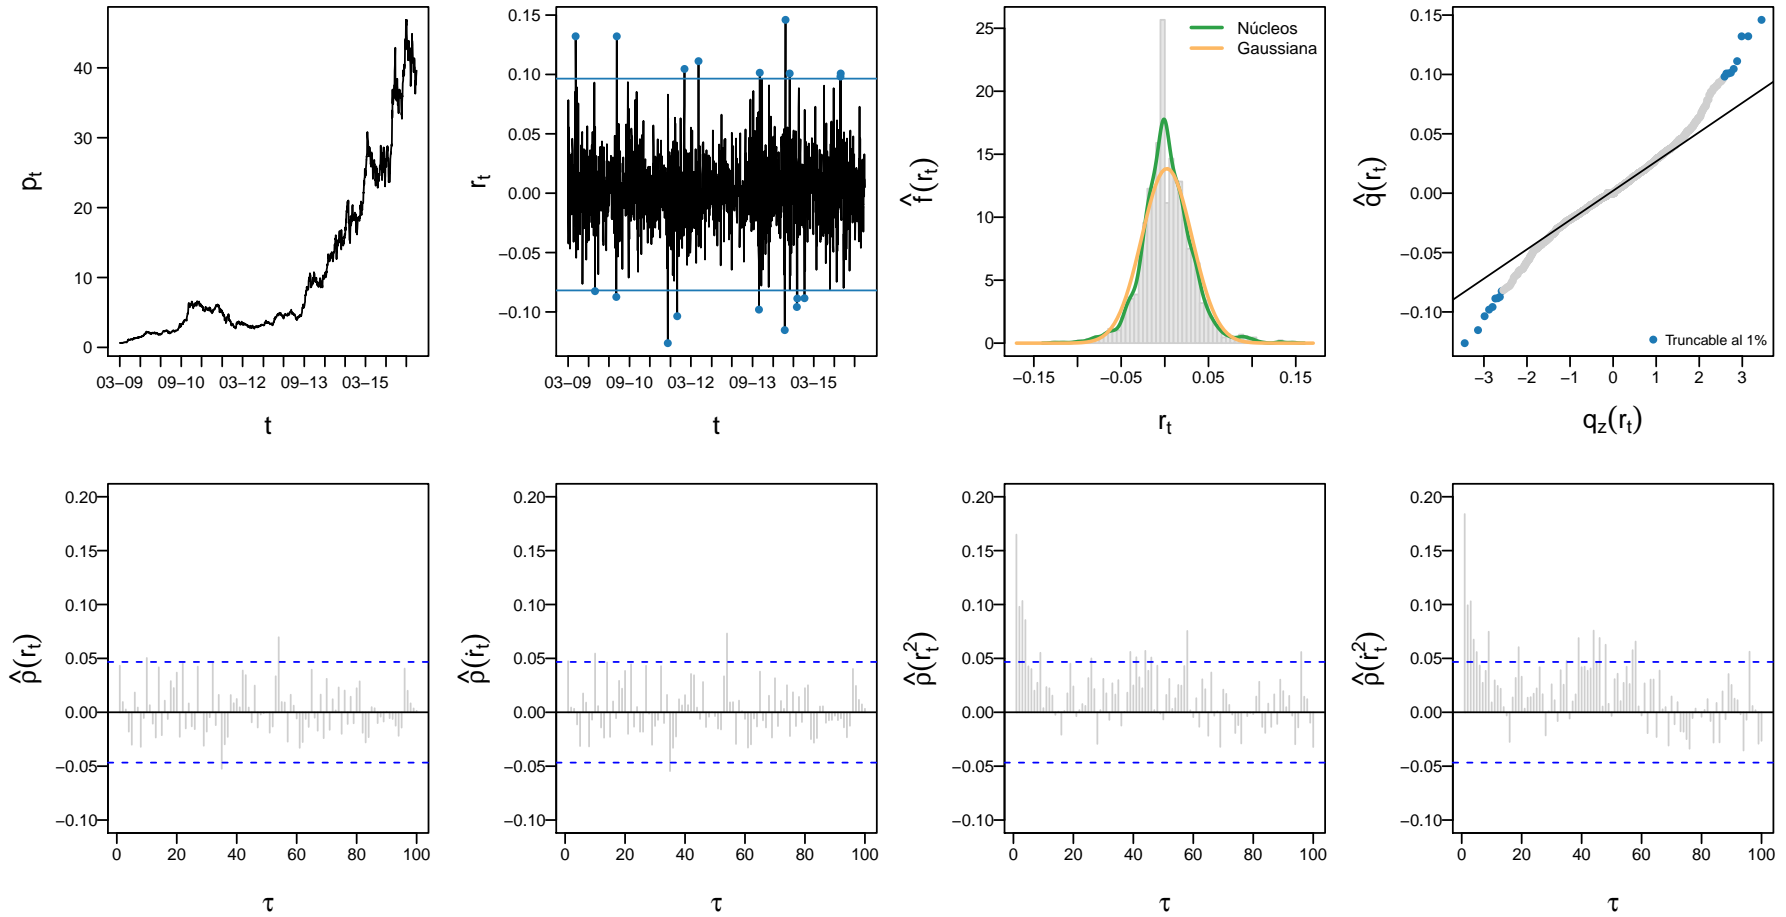


Figura A.6: Análisis exploratorio de FRAN.

**Arriba** Primero: Serie histórica de precios. Segundo: Serie histórica del retorno logarítmico. Los puntos azules destacan aquellas observaciones que serían truncadas al 1%. Las líneas marcan el valor del cuantil. Tercero: Histograma de los retornos logarítmicos. Los parámetros de la distribución gaussiana son estimados por máxima verosimilitud en  $\hat{\mu} = 2.207E - 03$  y  $\hat{\sigma}^2 = 2.957E - 02$ . La densidad por núcleos es estimada mediante un kernel gaussiano y un ancho de ventana de  $5.424E - 03$  seleccionado por Sheather y Jones (1991). Cuarto: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. **Abajo** Primero: Autocorrelograma para los retornos logarítmicos (datos originales). Segundo: Autocorrelograma para los retornos logarítmicos (datos truncados al 1%). Tercero: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos originales). Cuarto: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos truncados al 1%). Elaboración propia.

ANEXO A  
 Hechos estilizados sobre los retornos y la volatilidad  
 Retornos (GGAL)

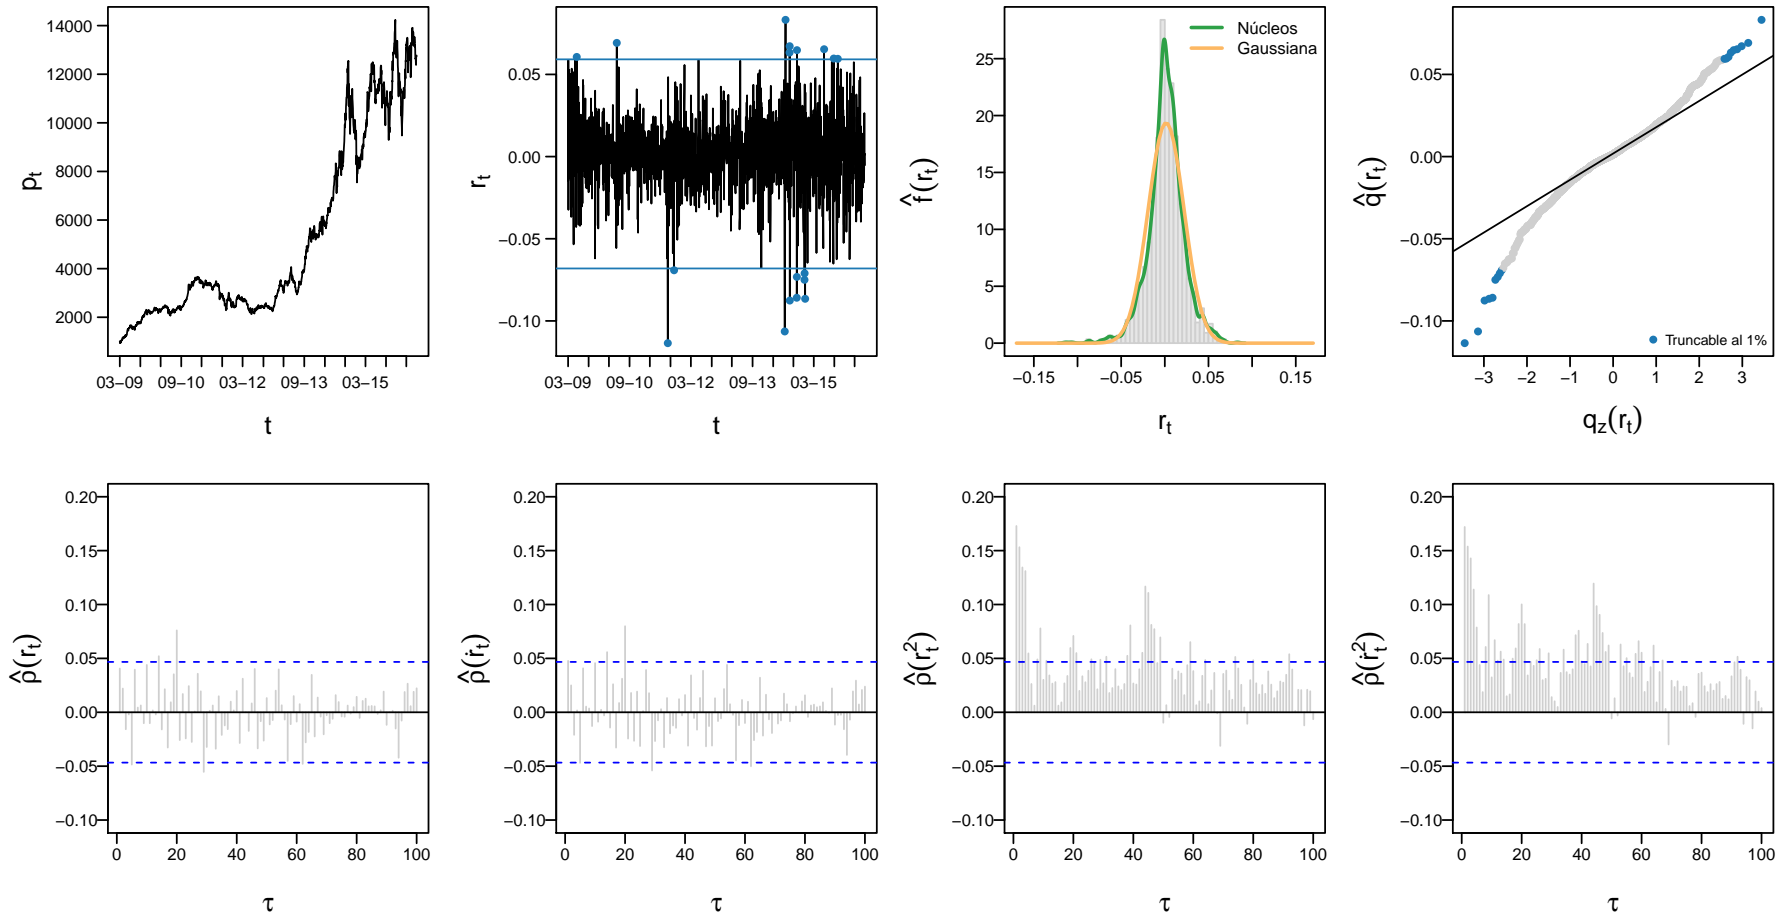


**Figura A.7:** Análisis exploratorio de GGAL.

**Arriba** Primero: Serie histórica de precios. Segundo: Serie histórica del retorno logarítmico. Los puntos azules destacan aquellas observaciones que serían truncadas al 1%. Las líneas marcan el valor del cuantil. Tercero: Histograma de los retornos logarítmicos. Los parámetros de la distribución gaussiana son estimados por máxima verosimilitud en  $\hat{\mu} = 2.371E - 03$  y  $\hat{\sigma}^2 = 2.878E - 02$ . La densidad por núcleos es estimada mediante un kernel gaussiano y un ancho de ventana de  $4.644E - 03$  seleccionado por Sheather y Jones (1991). Cuarto: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. **Abajo** Primero: Autocorrelograma para los retornos logarítmicos (datos originales). Segundo: Autocorrelograma para los retornos logarítmicos (datos truncados al 1%). Tercero: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos originales). Cuarto: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos truncados al 1%). Elaboración propia.



**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Retornos (Merval)



**Figura A.8:** Análisis exploratorio de Merval.

**Arriba** Primero: Serie histórica de precios. Segundo: Serie histórica del retorno logarítmico. Los puntos azules destacan aquellas observaciones que serían truncadas al 1%. Las líneas marcan el valor del cuantil. Tercero: Histograma de los retornos logarítmicos. Los parámetros de la distribución gaussiana son estimados por máxima verosimilitud en  $\hat{\mu} = 1.476E - 03$  y  $\hat{\sigma}^2 = 2.061E - 02$ . La densidad por núcleos es estimada mediante un kernel gaussiano y un ancho de ventana de  $2.962E - 03$  seleccionado por Sheather y Jones (1991). Cuarto: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. **Abajo** Primero: Autocorrelograma para los retornos logarítmicos (datos originales). Segundo: Autocorrelograma para los retornos logarítmicos (datos truncados al 1%). Tercero: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos originales). Cuarto: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos truncados al 1%). Elaboración propia.

ANEXO A  
 Hechos estilizados sobre los retornos y la volatilidad  
 Retornos (PAMP)

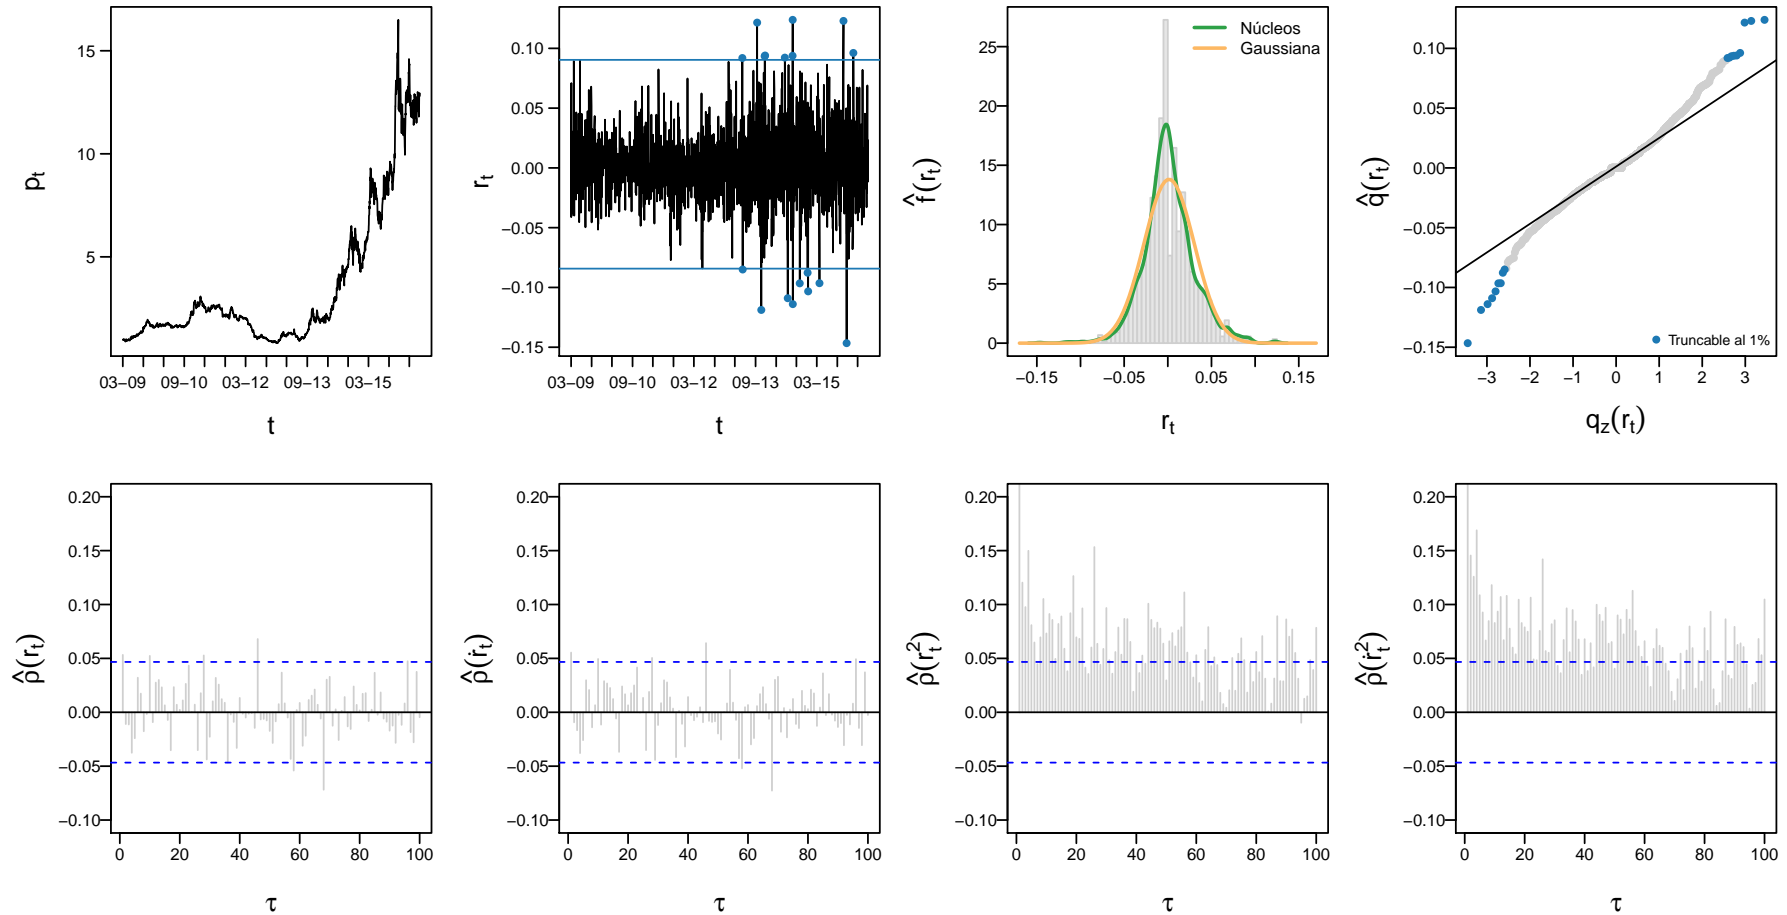
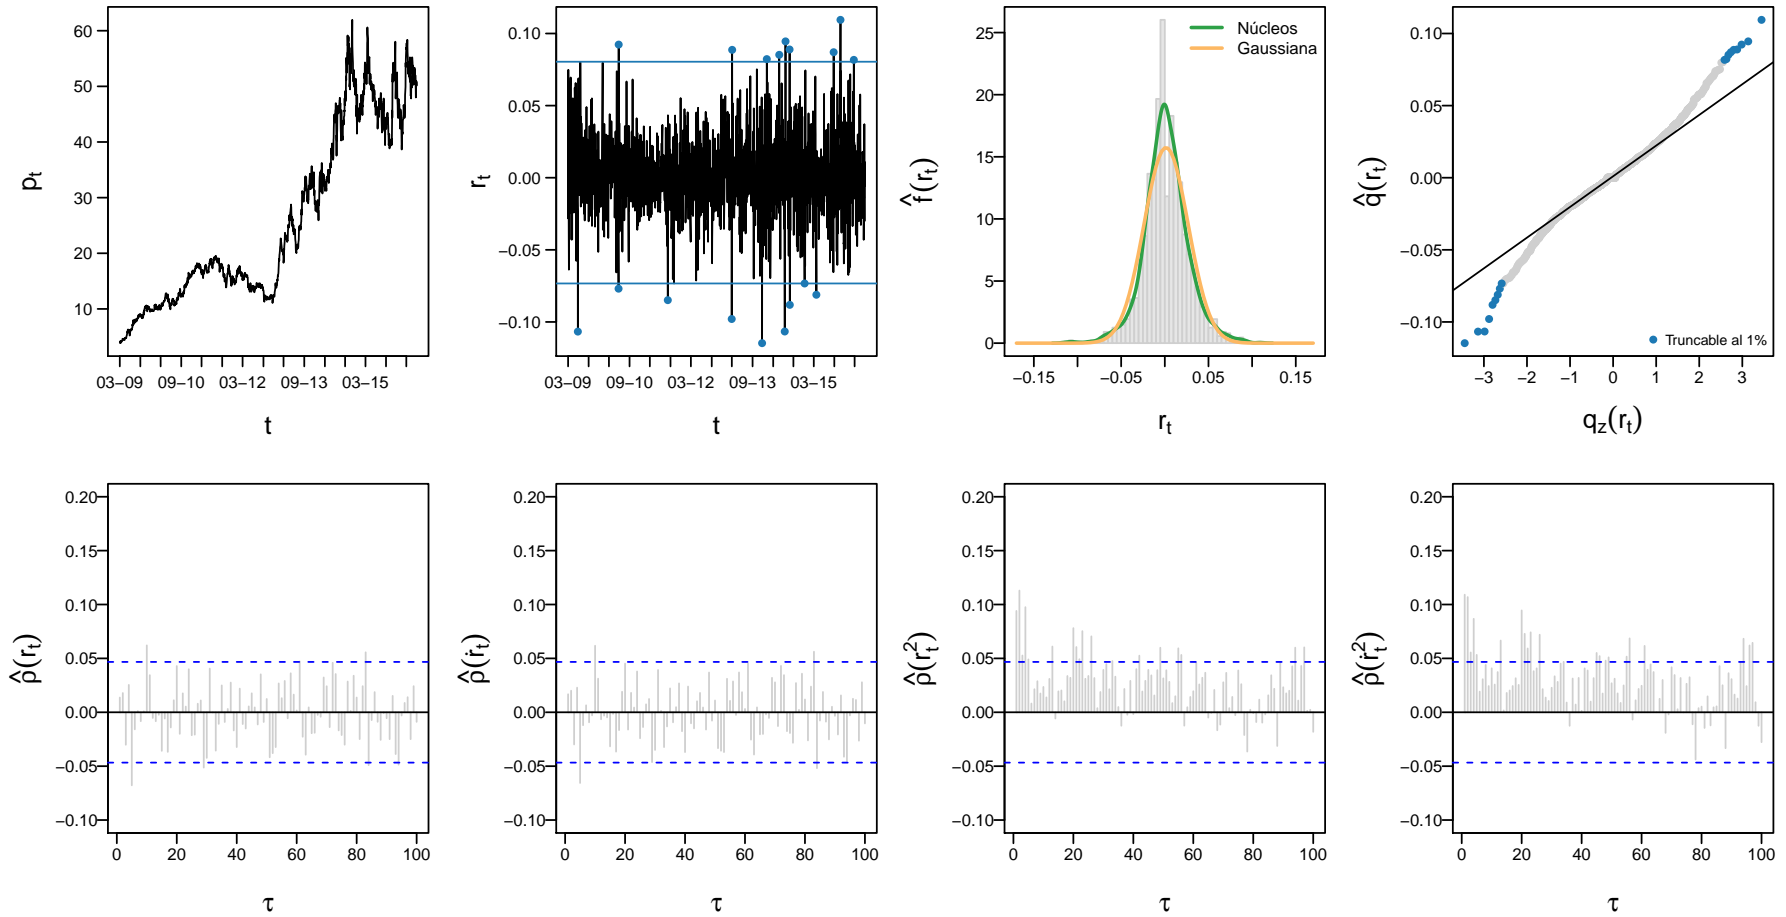


Figura A.9: Análisis exploratorio de PAMP.

Arriba Primero: Serie histórica de precios. Segundo: Serie histórica del retorno logarítmico. Los puntos azules destacan aquellas observaciones que serían truncadas al 1%. Las líneas marcan el valor del cuantil. Tercero: Histograma de los retornos logarítmicos. Los parámetros de la distribución gaussiana son estimados por máxima verosimilitud en  $\hat{\mu} = 1.465E - 03$  y  $\hat{\sigma}^2 = 2.887E - 02$ . La densidad por núcleos es estimada mediante un kernel gaussiano y un ancho de ventana de  $4.329E - 03$  seleccionado por Sheather y Jones (1991). Cuarto: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. Abajo Primero: Autocorrelograma para los retornos logarítmicos (datos originales). Segundo: Autocorrelograma para los retornos logarítmicos (datos truncados al 1%). Tercero: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos originales). Cuarto: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos truncados al 1%). Elaboración propia.

ANEXO A  
 Hechos estilizados sobre los retornos y la volatilidad  
 Retornos (TECO2)



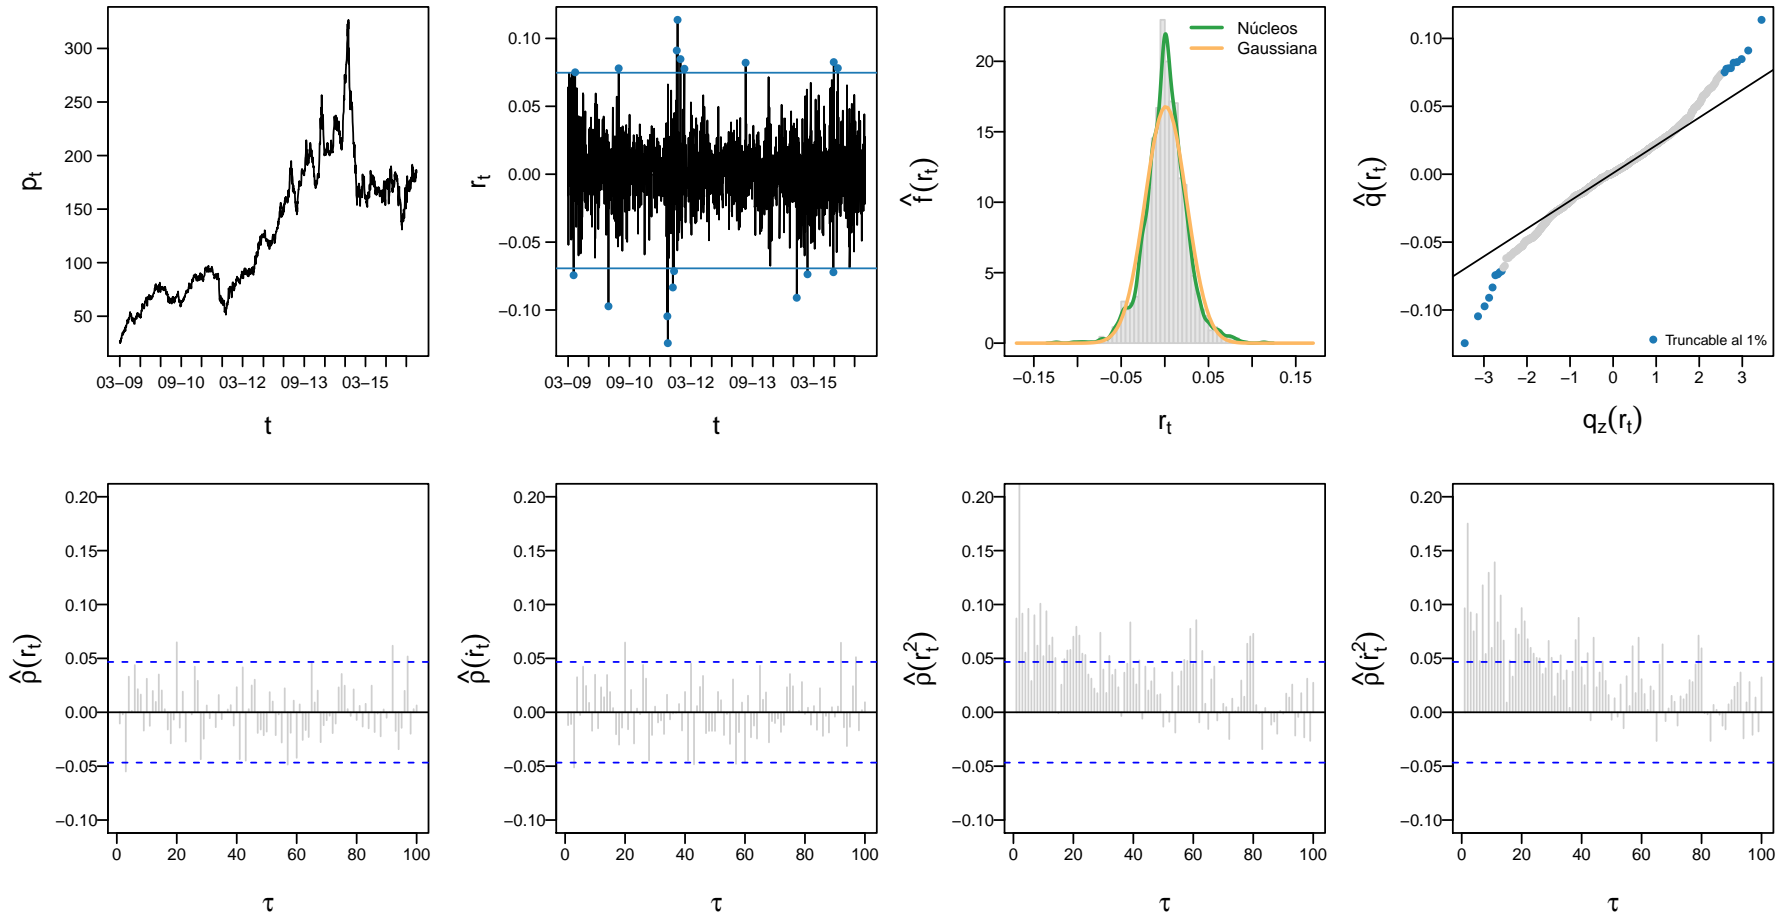
**Figura A.10:** Análisis exploratorio de TECO2.

**Arriba** Primero: Serie histórica de precios. Segundo: Serie histórica del retorno logarítmico. Los puntos azules destacan aquellas observaciones que serían truncadas al 1%. Las líneas marcan el valor del cuantil. Tercero: Histograma de los retornos logarítmicos. Los parámetros de la distribución gaussiana son estimados por máxima verosimilitud en  $\hat{\mu} = 1.441E - 03$  y  $\hat{\sigma}^2 = 2.534E - 02$ . La densidad por núcleos es estimada mediante un kernel gaussiano y un ancho de ventana de  $4.680E - 03$  seleccionado por Sheather y Jones (1991). Cuarto: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. **Abajo** Primero: Autocorrelograma para los retornos logarítmicos (datos originales). Segundo: Autocorrelograma para los retornos logarítmicos (datos truncados al 1%). Tercero: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos originales). Cuarto: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos truncados al 1%). Elaboración propia.

# ANEXO A

## Hechos estilizados sobre los retornos y la volatilidad

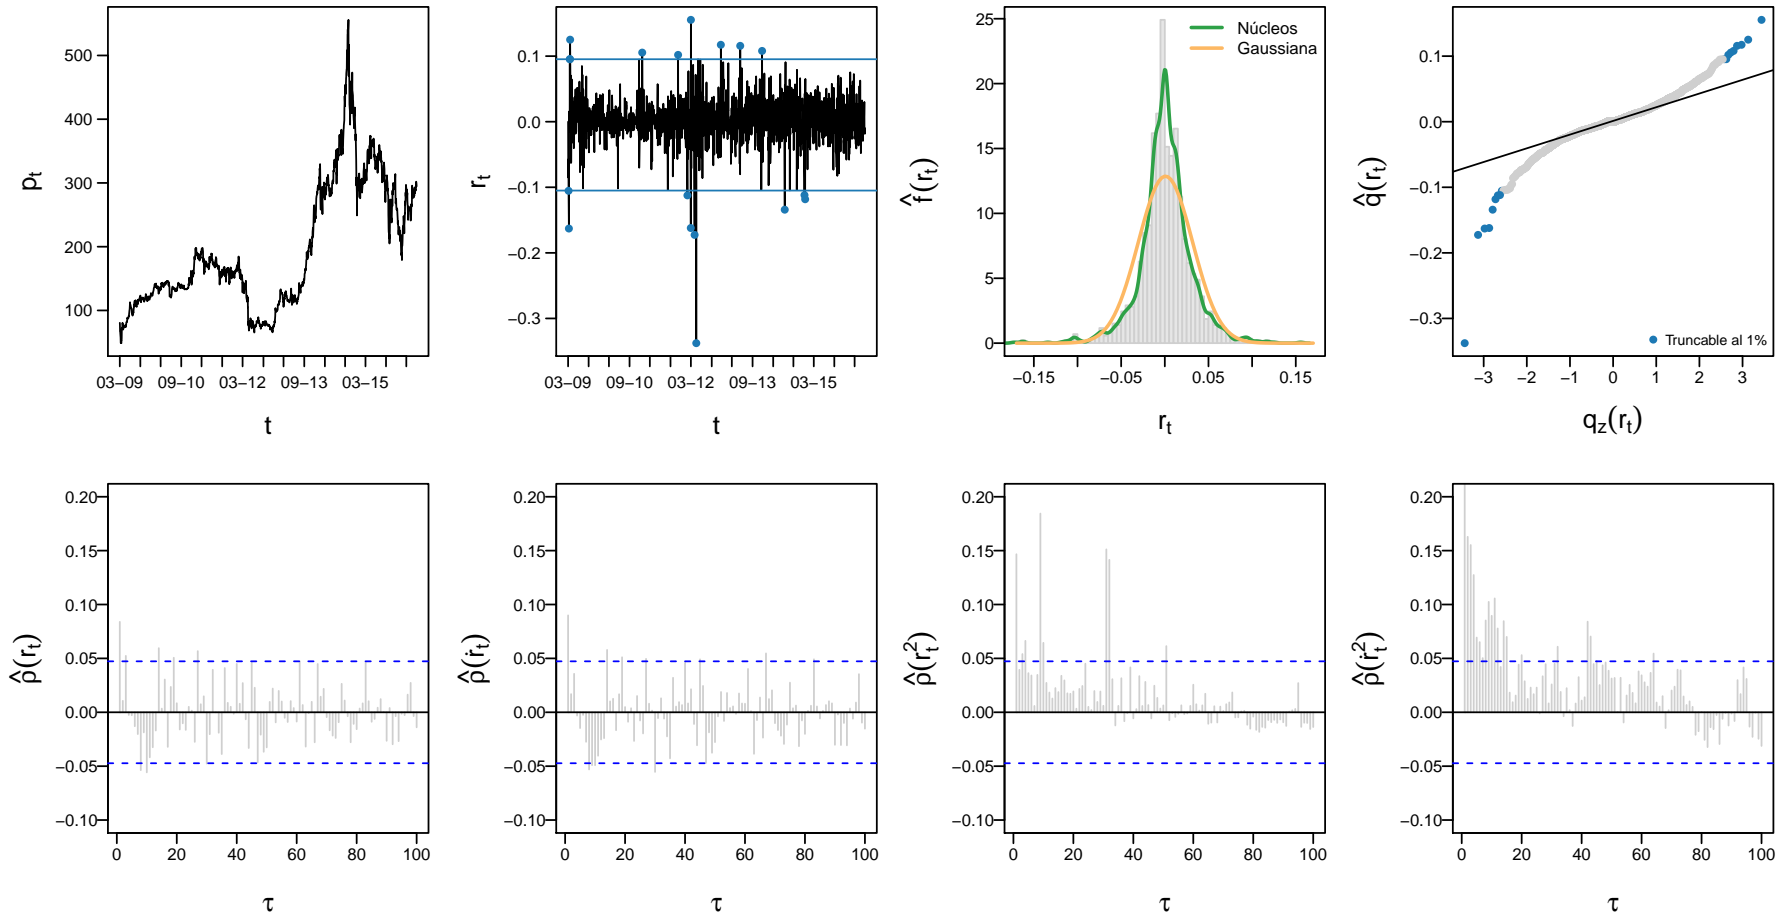
### Retornos (TS)



**Figura A.11:** Análisis exploratorio de TS.

**Arriba** Primero: Serie histórica de precios. Segundo: Serie histórica del retorno logarítmico. Los puntos azules destacan aquellas observaciones que serían truncadas al 1%. Las líneas marcan el valor del cuantil. Tercero: Histograma de los retornos logarítmicos. Los parámetros de la distribución gaussiana son estimados por máxima verosimilitud en  $\hat{\mu} = 1.136E - 03$  y  $\hat{\sigma}^2 = 2.376E - 02$ . La densidad por núcleos es estimada mediante un kernel gaussiano y un ancho de ventana de  $3.593E - 03$  seleccionado por [Sheather y Jones \(1991\)](#). Cuarto: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. **Abajo** Primero: Autocorrelograma para los retornos logarítmicos (datos originales). Segundo: Autocorrelograma para los retornos logarítmicos (datos truncados al 1%). Tercero: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos originales). Cuarto: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos truncados al 1%). Elaboración propia.


**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Retornos (YFPD)




**Figura A.12:** Análisis exploratorio de YFPD.

**Arriba** Primero: Serie histórica de precios. Segundo: Serie histórica del retorno logarítmico. Los puntos azules destacan aquellas observaciones que serían truncadas al 1%. Las líneas marcan el valor del cuantil. Tercero: Histograma de los retornos logarítmicos. Los parámetros de la distribución gaussiana son estimados por máxima verosimilitud en  $\hat{\mu} = 7.597E - 04$  y  $\hat{\sigma}^2 = 3.101E - 02$ . La densidad por núcleos es estimada mediante un kernel gaussiano y un ancho de ventana de  $3.513E - 03$  seleccionado por [Sheather y Jones \(1991\)](#). Cuarto: gráfico de cuantil-cuantil de los retornos logarítmicos para una distribución gaussiana. **Abajo** Primero: Autocorrelograma para los retornos logarítmicos (datos originales). Segundo: Autocorrelograma para los retornos logarítmicos (datos truncados al 1%). Tercero: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos originales). Cuarto: Autocorrelograma para el cuadrado de los retornos logarítmicos (datos truncados al 1%). Elaboración propia.

**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Estimadores de la volatilidad (APBR)



**Figura A.13:** Serie de tiempo de la volatilidad diaria estimada empleando una ventana móvil de diez observaciones. Elaboración propia.



	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8744	0.8425	0.8082	0.8797
$\hat{\sigma}_{park}$	0.8744	1.0000	0.9854	0.9566	0.9303
$\hat{\sigma}_{gk}$	0.8425	0.9854	1.0000	0.9908	0.9454
$\hat{\sigma}_{rs}$	0.8082	0.9566	0.9908	1.0000	0.9428
$\hat{\sigma}_{yz}$	0.8797	0.9303	0.9454	0.9428	1.0000


**Cuadro A.2:** Correlación de Pearson para los datos originales. Elaboración propia.

	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8653	0.8250	0.7834	0.8605
$\hat{\sigma}_{park}$	0.8653	1.0000	0.9832	0.9497	0.9228
$\hat{\sigma}_{gk}$	0.8250	0.9832	1.0000	0.9893	0.9398
$\hat{\sigma}_{rs}$	0.7834	0.9497	0.9893	1.0000	0.9359
$\hat{\sigma}_{yz}$	0.8605	0.9228	0.9398	0.9359	1.0000

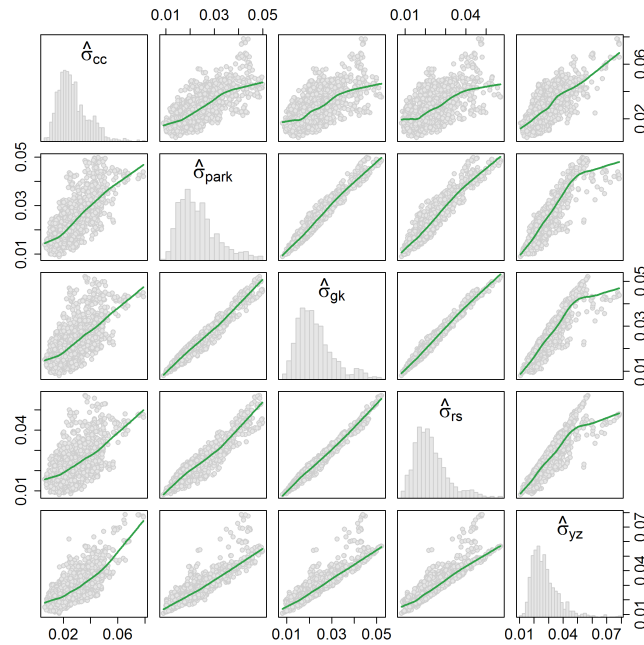
**Cuadro A.3:** Correlación de Pearson para los datos truncados al 1%. Elaboración propia.

**Figura A.14:** Matriz de gráficos de dispersión para la volatilidad diaria estimada por los estimadores cierre a cierre, Parkinson, Garman-Klass, Rogers-Satchell y Yang-Zhang. En todos los casos se emplea una ventana móvil de diez observaciones. Elaboración propia.

**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Estimadores de la volatilidad (BMA)



**Figura A.15:** Serie de tiempo de la volatilidad diaria estimada empleando una ventana móvil de diez observaciones. Elaboración propia.



	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.7412	0.6700	0.6046	0.7574
$\hat{\sigma}_{park}$	0.7412	1.0000	0.9771	0.9373	0.8899
$\hat{\sigma}_{gk}$	0.6700	0.9771	1.0000	0.9876	0.9035
$\hat{\sigma}_{rs}$	0.6046	0.9373	0.9876	1.0000	0.8934
$\hat{\sigma}_{yz}$	0.7574	0.8899	0.9035	0.8934	1.0000


**Cuadro A.4:** Correlación de Pearson para los datos originales. Elaboración propia.

	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.7351	0.6486	0.5676	0.7145
$\hat{\sigma}_{park}$	0.7351	1.0000	0.9743	0.9290	0.9077
$\hat{\sigma}_{gk}$	0.6486	0.9743	1.0000	0.9857	0.9189
$\hat{\sigma}_{rs}$	0.5676	0.9290	0.9857	1.0000	0.9023
$\hat{\sigma}_{yz}$	0.7145	0.9077	0.9189	0.9023	1.0000


**Cuadro A.5:** Correlación de Pearson para los datos truncados al 1%. Elaboración propia.

**Figura A.16:** Matriz de gráficos de dispersión para la volatilidad diaria estimada por los estimadores cierre a cierre, Parkinson, Garman-Klass, Rogers-Satchell y Yang-Zhang. En todos los casos se emplea una ventana móvil de diez observaciones. Elaboración propia.

**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Estimadores de la volatilidad (COME)



**Figura A.17:** Serie de tiempo de la volatilidad diaria estimada empleando una ventana móvil de diez observaciones. Elaboración propia.



	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8050	0.7414	0.6779	0.6177
$\hat{\sigma}_{park}$	0.8050	1.0000	0.9769	0.9277	0.8620
$\hat{\sigma}_{gk}$	0.7414	0.9769	1.0000	0.9816	0.8306
$\hat{\sigma}_{rs}$	0.6779	0.9277	0.9816	1.0000	0.7897
$\hat{\sigma}_{yz}$	0.6177	0.8620	0.8306	0.7897	1.0000

**Cuadro A.6:** Correlación de Pearson para los datos originales. Elaboración propia.


	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8057	0.7078	0.6307	0.7246
$\hat{\sigma}_{park}$	0.8057	1.0000	0.9740	0.9253	0.8959
$\hat{\sigma}_{gk}$	0.7078	0.9740	1.0000	0.9816	0.9181
$\hat{\sigma}_{rs}$	0.6307	0.9253	0.9816	1.0000	0.9219
$\hat{\sigma}_{yz}$	0.7246	0.8959	0.9181	0.9219	1.0000

**Cuadro A.7:** Correlación de Pearson para los datos truncados al 1%. Elaboración propia.

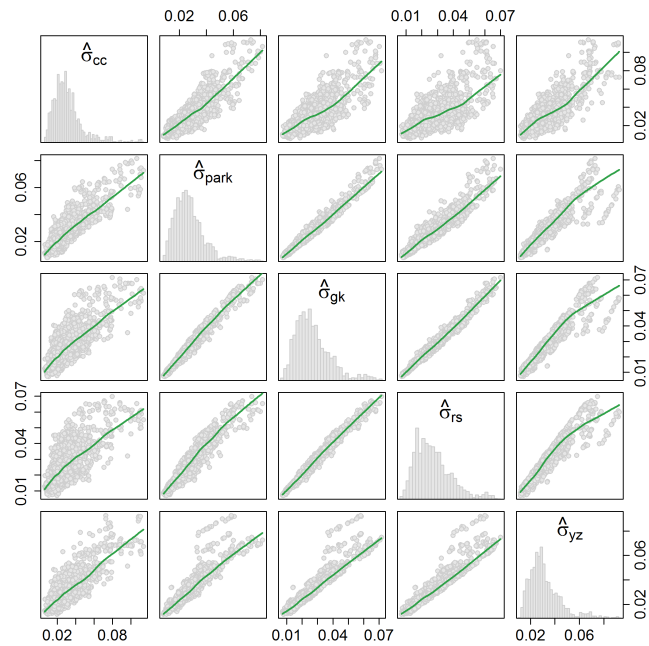
**Figura A.18:** Matriz de gráficos de dispersión para la volatilidad diaria estimada por los estimadores cierre a cierre, Parkinson, Garman-Klass, Rogers-Satchell y Yang-Zhang. En todos los casos se emplea una ventana móvil de diez observaciones. Elaboración propia.



**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Estimadores de la volatilidad (EDN)



**Figura A.19:** Serie de tiempo de la volatilidad diaria estimada empleando una ventana móvil de diez observaciones. Elaboración propia.



	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8501	0.7785	0.7145	0.8121
$\hat{\sigma}_{park}$	0.8501	1.0000	0.9787	0.9408	0.9115
$\hat{\sigma}_{gk}$	0.7785	0.9787	1.0000	0.9877	0.9336
$\hat{\sigma}_{rs}$	0.7145	0.9408	0.9877	1.0000	0.9315
$\hat{\sigma}_{yz}$	0.8121	0.9115	0.9336	0.9315	1.0000


**Cuadro A.8:** Correlación de Pearson para los datos originales. Elaboración propia.

	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8275	0.7350	0.6568	0.7549
$\hat{\sigma}_{park}$	0.8275	1.0000	0.9761	0.9342	0.9381
$\hat{\sigma}_{gk}$	0.7350	0.9761	1.0000	0.9863	0.9572
$\hat{\sigma}_{rs}$	0.6568	0.9342	0.9863	1.0000	0.9506
$\hat{\sigma}_{yz}$	0.7549	0.9381	0.9572	0.9506	1.0000

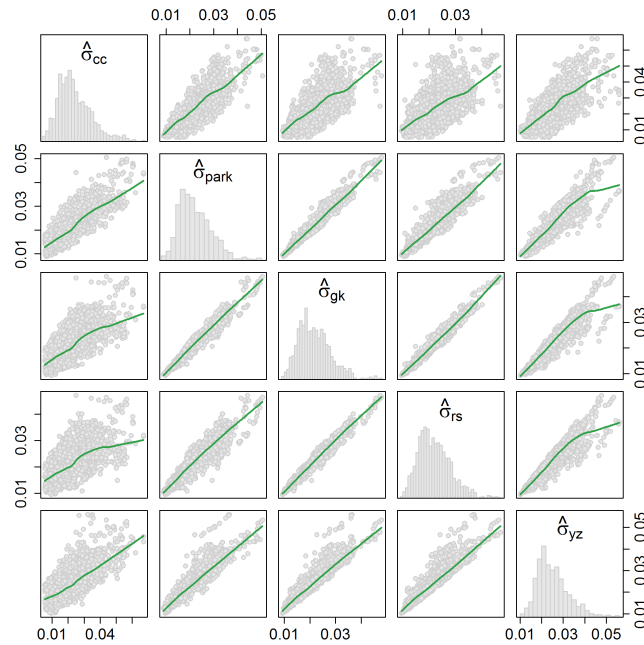
**Cuadro A.9:** Correlación de Pearson para los datos truncados al 1%. Elaboración propia.

**Figura A.20:** Matriz de gráficos de dispersión para la volatilidad diaria estimada por los estimadores cierre a cierre, Parkinson, Garman-Klass, Rogers-Satchell y Yang-Zhang. En todos los casos se emplea una ventana móvil de diez observaciones. Elaboración propia.

**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Estimadores de la volatilidad (ERAR)



**Figura A.21:** Serie de tiempo de la volatilidad diaria estimada empleando una ventana móvil de diez observaciones. Elaboración propia.



	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8109	0.7070	0.6137	0.7334
$\hat{\sigma}_{park}$	0.8109	1.0000	0.9686	0.9108	0.8978
$\hat{\sigma}_{gk}$	0.7070	0.9686	1.0000	0.9808	0.9173
$\hat{\sigma}_{rs}$	0.6137	0.9108	0.9808	1.0000	0.9077
$\hat{\sigma}_{yz}$	0.7334	0.8978	0.9173	0.9077	1.0000


**Cuadro A.10:** Correlación de Pearson para los datos originales. Elaboración propia.

	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8072	0.7013	0.6077	0.7313
$\hat{\sigma}_{park}$	0.8072	1.0000	0.9691	0.9121	0.9132
$\hat{\sigma}_{gk}$	0.7013	0.9691	1.0000	0.9807	0.9320
$\hat{\sigma}_{rs}$	0.6077	0.9121	0.9807	1.0000	0.9214
$\hat{\sigma}_{yz}$	0.7313	0.9132	0.9320	0.9214	1.0000


**Cuadro A.11:** Correlación de Pearson para los datos truncados al 1%. Elaboración propia.

**Figura A.22:** Matriz de gráficos de dispersión para la volatilidad diaria estimada por los estimadores cierre a cierre, Parkinson, Garman-Klass, Rogers-Satchell y Yang-Zhang. En todos los casos se emplea una ventana móvil de diez observaciones. Elaboración propia.

**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Estimadores de la volatilidad (FRAN)



**Figura A.23:** Serie de tiempo de la volatilidad diaria estimada empleando una ventana móvil de diez observaciones. Elaboración propia.



**Figura A.24:** Matriz de gráficos de dispersión para la volatilidad diaria estimada por los estimadores cierre a cierre, Parkinson, Garman-Klass, Rogers-Satchell y Yang-Zhang. En todos los casos se emplea una ventana móvil de diez observaciones. Elaboración propia.


	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.7592	0.6825	0.6110	0.6828
$\hat{\sigma}_{park}$	0.7592	1.0000	0.9705	0.9179	0.8815
$\hat{\sigma}_{gk}$	0.6825	0.9705	1.0000	0.9827	0.8964
$\hat{\sigma}_{rs}$	0.6110	0.9179	0.9827	1.0000	0.8822
$\hat{\sigma}_{yz}$	0.6828	0.8815	0.8964	0.8822	1.0000

**Cuadro A.12:** Correlación de Pearson para los datos originales. Elaboración propia.


	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.7694	0.6702	0.5877	0.6893
$\hat{\sigma}_{park}$	0.7694	1.0000	0.9690	0.9140	0.8888
$\hat{\sigma}_{gk}$	0.6702	0.9690	1.0000	0.9820	0.9117
$\hat{\sigma}_{rs}$	0.5877	0.9140	0.9820	1.0000	0.9031
$\hat{\sigma}_{yz}$	0.6893	0.8888	0.9117	0.9031	1.0000

**Cuadro A.13:** Correlación de Pearson para los datos truncados al 1%. Elaboración propia.

**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Estimadores de la volatilidad (GGAL)



**Figura A.25:** Serie de tiempo de la volatilidad diaria estimada empleando una ventana móvil de diez observaciones. Elaboración propia.



	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8270	0.7575	0.6866	0.7901
$\hat{\sigma}_{park}$	0.8270	1.0000	0.9760	0.9317	0.8938
$\hat{\sigma}_{gk}$	0.7575	0.9760	1.0000	0.9857	0.9214
$\hat{\sigma}_{rs}$	0.6866	0.9317	0.9857	1.0000	0.9155
$\hat{\sigma}_{yz}$	0.7901	0.8938	0.9214	0.9155	1.0000


**Cuadro A.14:** Correlación de Pearson para los datos originales. Elaboración propia.

	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8140	0.7300	0.6491	0.7623
$\hat{\sigma}_{park}$	0.8140	1.0000	0.9733	0.9237	0.8944
$\hat{\sigma}_{gk}$	0.7300	0.9733	1.0000	0.9841	0.9178
$\hat{\sigma}_{rs}$	0.6491	0.9237	0.9841	1.0000	0.9076
$\hat{\sigma}_{yz}$	0.7623	0.8944	0.9178	0.9076	1.0000

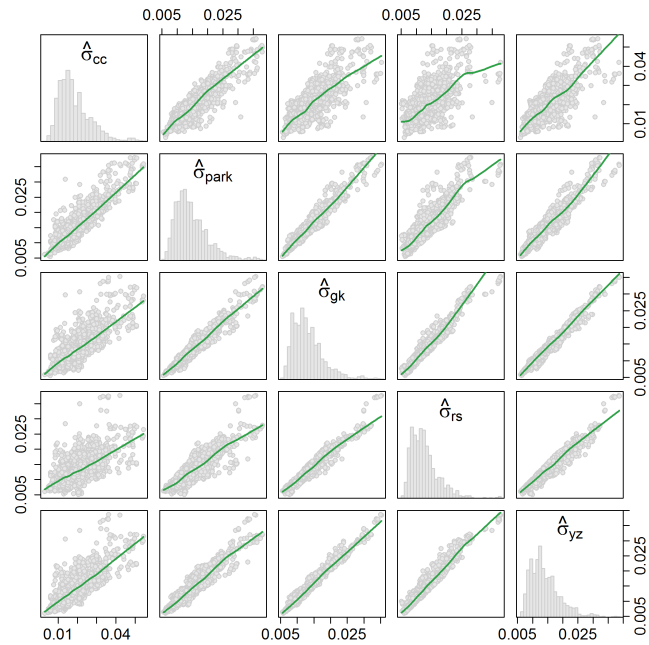
**Cuadro A.15:** Correlación de Pearson para los datos truncados al 1%. Elaboración propia.

**Figura A.26:** Matriz de gráficos de dispersión para la volatilidad diaria estimada por los estimadores cierre a cierre, Parkinson, Garman-Klass, Rogers-Satchell y Yang-Zhang. En todos los casos se emplea una ventana móvil de diez observaciones. Elaboración propia.

**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Estimadores de la volatilidad (Merval)



**Figura A.27:** Serie de tiempo de la volatilidad diaria estimada empleando una ventana móvil de diez observaciones. Elaboración propia.



	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8936	0.7881	0.6552	0.8024
$\hat{\sigma}_{park}$	0.8936	1.0000	0.9651	0.8773	0.9469
$\hat{\sigma}_{gk}$	0.7881	0.9651	1.0000	0.9694	0.9823
$\hat{\sigma}_{rs}$	0.6552	0.8773	0.9694	1.0000	0.9624
$\hat{\sigma}_{yz}$	0.8024	0.9469	0.9823	0.9624	1.0000


**Cuadro A.16:** Correlación de Pearson para los datos originales. Elaboración propia.

	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8886	0.7768	0.6385	0.7939
$\hat{\sigma}_{park}$	0.8886	1.0000	0.9627	0.8705	0.9412
$\hat{\sigma}_{gk}$	0.7768	0.9627	1.0000	0.9680	0.9793
$\hat{\sigma}_{rs}$	0.6385	0.8705	0.9680	1.0000	0.9592
$\hat{\sigma}_{yz}$	0.7939	0.9412	0.9793	0.9592	1.0000


**Cuadro A.17:** Correlación de Pearson para los datos truncados al 1%. Elaboración propia.

**Figura A.28:** Matriz de gráficos de dispersión para la volatilidad diaria estimada por los estimadores cierre a cierre, Parkinson, Garman-Klass, Rogers-Satchell y Yang-Zhang. En todos los casos se emplea una ventana móvil de diez observaciones. Elaboración propia.

**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Estimadores de la volatilidad (PAMP)



**Figura A.29:** Serie de tiempo de la volatilidad diaria estimada empleando una ventana móvil de diez observaciones. Elaboración propia.



	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8423	0.7664	0.7015	0.8052
$\hat{\sigma}_{park}$	0.8423	1.0000	0.9762	0.9348	0.9220
$\hat{\sigma}_{gk}$	0.7664	0.9762	1.0000	0.9857	0.9327
$\hat{\sigma}_{rs}$	0.7015	0.9348	0.9857	1.0000	0.9205
$\hat{\sigma}_{yz}$	0.8052	0.9220	0.9327	0.9205	1.0000


**Cuadro A.18:** Correlación de Pearson para los datos originales. Elaboración propia.

	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8440	0.7633	0.6979	0.8015
$\hat{\sigma}_{park}$	0.8440	1.0000	0.9754	0.9341	0.9417
$\hat{\sigma}_{gk}$	0.7633	0.9754	1.0000	0.9860	0.9498
$\hat{\sigma}_{rs}$	0.6979	0.9341	0.9860	1.0000	0.9366
$\hat{\sigma}_{yz}$	0.8015	0.9417	0.9498	0.9366	1.0000

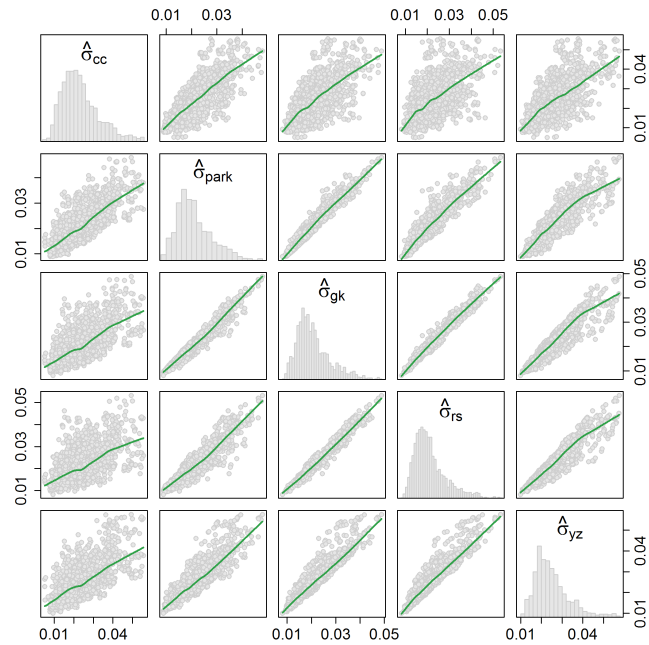
**Cuadro A.19:** Correlación de Pearson para los datos truncados al 1%. Elaboración propia.

**Figura A.30:** Matriz de gráficos de dispersión para la volatilidad diaria estimada por los estimadores cierre a cierre, Parkinson, Garman-Klass, Rogers-Satchell y Yang-Zhang. En todos los casos se emplea una ventana móvil de diez observaciones. Elaboración propia.

**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Estimadores de la volatilidad (TECO2)



**Figura A.31:** Serie de tiempo de la volatilidad diaria estimada empleando una ventana móvil de diez observaciones. Elaboración propia.



	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.7666	0.6769	0.5901	0.6728
$\hat{\sigma}_{park}$	0.7666	1.0000	0.9708	0.9143	0.8820
$\hat{\sigma}_{gk}$	0.6769	0.9708	1.0000	0.9811	0.9239
$\hat{\sigma}_{rs}$	0.5901	0.9143	0.9811	1.0000	0.9265
$\hat{\sigma}_{yz}$	0.6728	0.8820	0.9239	0.9265	1.0000


**Cuadro A.20:** Correlación de Pearson para los datos originales. Elaboración propia.

	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.7595	0.6647	0.5735	0.6500
$\hat{\sigma}_{park}$	0.7595	1.0000	0.9691	0.9092	0.8788
$\hat{\sigma}_{gk}$	0.6647	0.9691	1.0000	0.9799	0.9222
$\hat{\sigma}_{rs}$	0.5735	0.9092	0.9799	1.0000	0.9238
$\hat{\sigma}_{yz}$	0.6500	0.8788	0.9222	0.9238	1.0000


**Cuadro A.21:** Correlación de Pearson para los datos truncados al 1%. Elaboración propia.

**Figura A.32:** Matriz de gráficos de dispersión para la volatilidad diaria estimada por los estimadores cierre a cierre, Parkinson, Garman-Klass, Rogers-Satchell y Yang-Zhang. En todos los casos se emplea una ventana móvil de diez observaciones. Elaboración propia.

**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Estimadores de la volatilidad (TS)



**Figura A.33:** Serie de tiempo de la volatilidad diaria estimada empleando una ventana móvil de diez observaciones. Elaboración propia.



	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.6976	0.6190	0.5499	0.7759
$\hat{\sigma}_{park}$	0.6976	1.0000	0.9726	0.9239	0.8333
$\hat{\sigma}_{gk}$	0.6190	0.9726	1.0000	0.9840	0.8523
$\hat{\sigma}_{rs}$	0.5499	0.9239	0.9840	1.0000	0.8420
$\hat{\sigma}_{yz}$	0.7759	0.8333	0.8523	0.8420	1.0000

**Cuadro A.22:** Correlación de Pearson para los datos originales. Elaboración propia.


	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.7091	0.6198	0.5457	0.7691
$\hat{\sigma}_{park}$	0.7091	1.0000	0.9678	0.9149	0.8158
$\hat{\sigma}_{gk}$	0.6198	0.9678	1.0000	0.9832	0.8427
$\hat{\sigma}_{rs}$	0.5457	0.9149	0.9832	1.0000	0.8361
$\hat{\sigma}_{yz}$	0.7691	0.8158	0.8427	0.8361	1.0000

**Cuadro A.23:** Correlación de Pearson para los datos truncados al 1%. Elaboración propia.

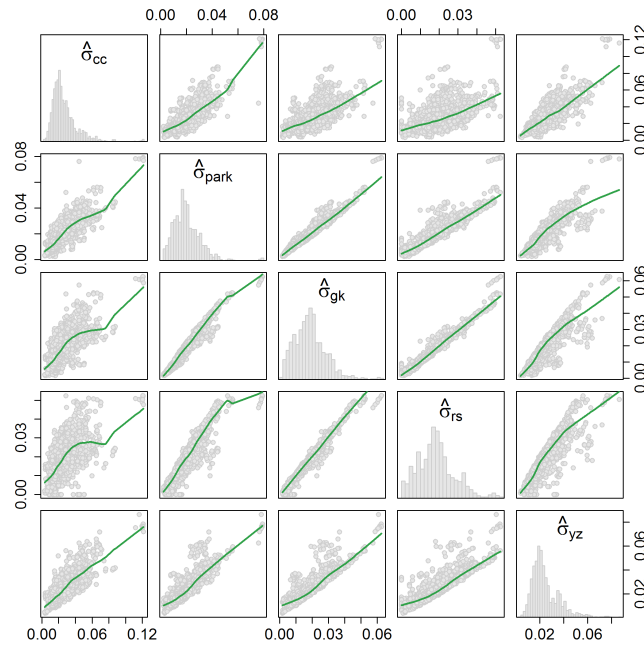
**Figura A.34:** Matriz de gráficos de dispersión para la volatilidad diaria estimada por los estimadores cierre a cierre, Parkinson, Garman-Klass, Rogers-Satchell y Yang-Zhang. En todos los casos se emplea una ventana móvil de diez observaciones. Elaboración propia.



**ANEXO A**  
**Hechos estilizados sobre los retornos y la volatilidad**  
 Estimadores de la volatilidad (YFPD)



**Figura A.35:** Serie de tiempo de la volatilidad diaria estimada empleando una ventana móvil de diez observaciones. Elaboración propia.



	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.8165	0.7086	0.5974	0.8107
$\hat{\sigma}_{park}$	0.8165	1.0000	0.9677	0.9024	0.8745
$\hat{\sigma}_{gk}$	0.7086	0.9677	1.0000	0.9793	0.8801
$\hat{\sigma}_{rs}$	0.5974	0.9024	0.9793	1.0000	0.8453
$\hat{\sigma}_{yz}$	0.8107	0.8745	0.8801	0.8453	1.0000

**Cuadro A.24:** Correlación de Pearson para los datos originales. Elaboración propia.

	$\hat{\sigma}_{cc}$	$\hat{\sigma}_{park}$	$\hat{\sigma}_{gk}$	$\hat{\sigma}_{rs}$	$\hat{\sigma}_{yz}$
$\hat{\sigma}_{cc}$	1.0000	0.7988	0.6989	0.6083	0.7753
$\hat{\sigma}_{park}$	0.7988	1.0000	0.9728	0.9236	0.8973
$\hat{\sigma}_{gk}$	0.6989	0.9728	1.0000	0.9852	0.9134
$\hat{\sigma}_{rs}$	0.6083	0.9236	0.9852	1.0000	0.8939
$\hat{\sigma}_{yz}$	0.7753	0.8973	0.9134	0.8939	1.0000

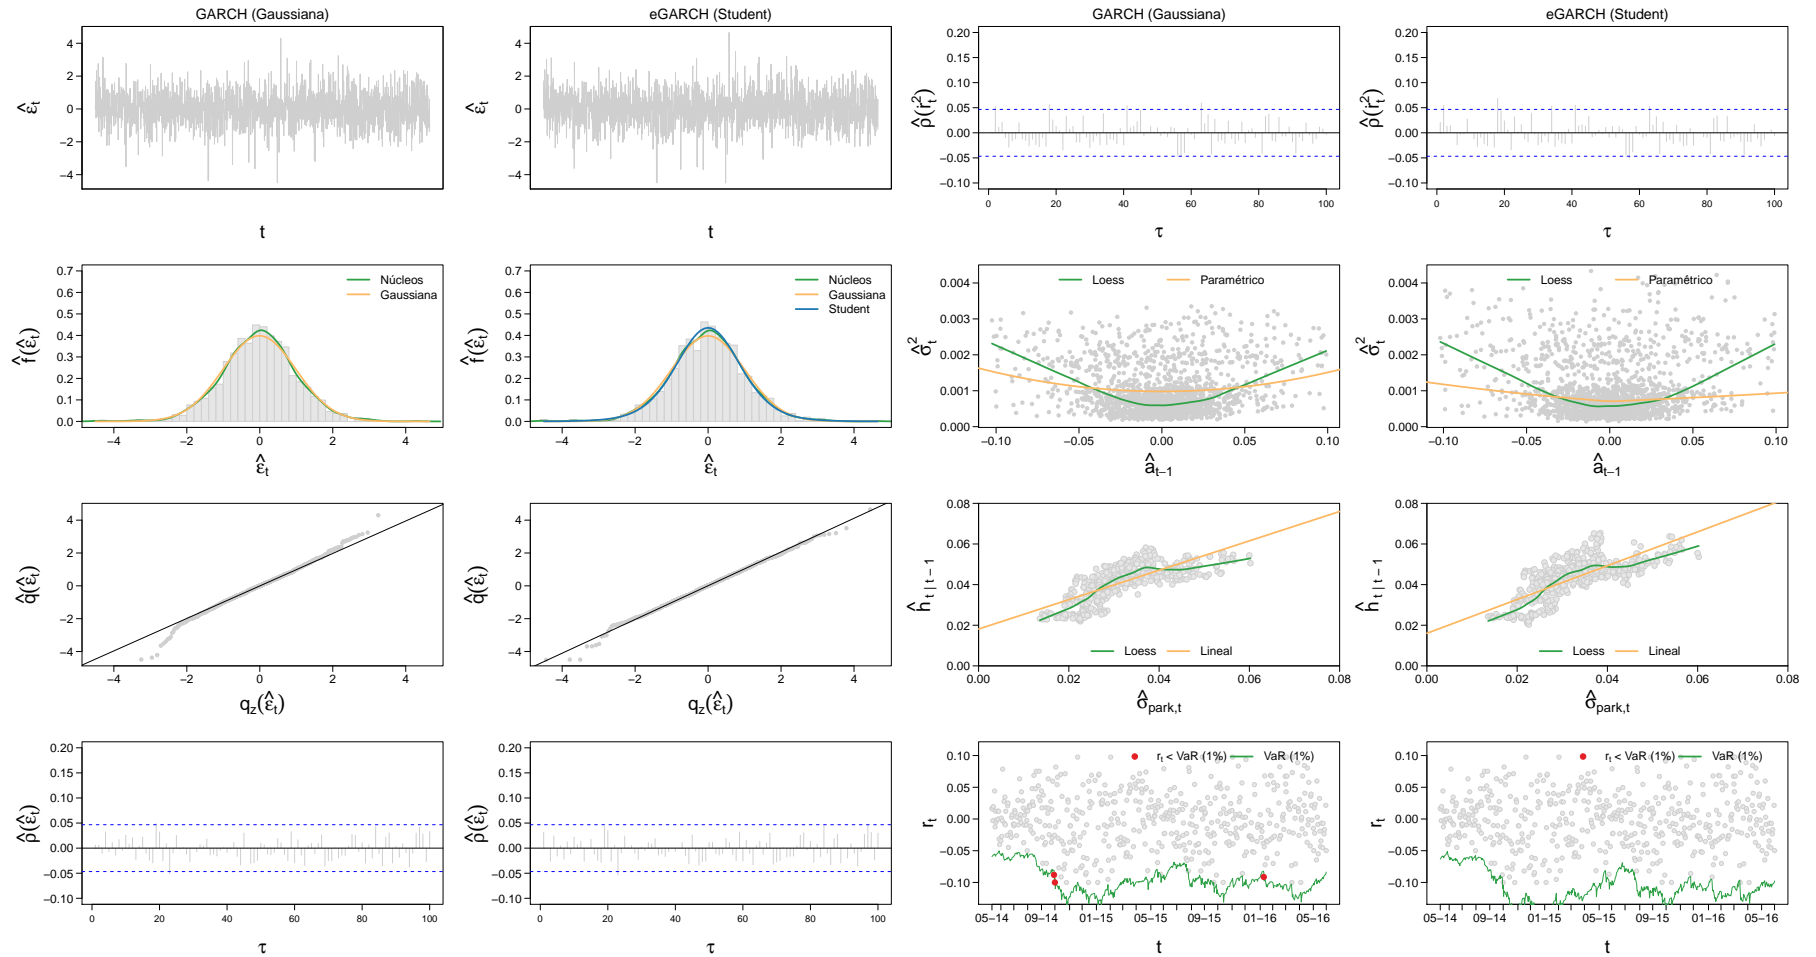
**Cuadro A.25:** Correlación de Pearson para los datos truncados al 1%. Elaboración propia.

**Figura A.36:** Matriz de gráficos de dispersión para la volatilidad diaria estimada por los estimadores cierre a cierre, Parkinson, Garman-Klass, Rogers-Satchell y Yang-Zhang. En todos los casos se emplea una ventana móvil de diez observaciones. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (APBR)



**Figura B.1:** Diagnóstico de residuos y evaluación de pronósticos para APBR (retornos truncados al 1%).  
**Columnas I y III** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución gaussiana. **Columnas II y IV** Modelo  $ARMA(1, 1) - eGARCH(1, 1)$  con distribución t de Student. **Columnas I y II** Primero: Serie de residuos estandarizados. Segundo: Histograma de los residuos estandarizados. Tercero: Gráfico de cuantil-cuantil de los residuos para la distribución supuesta por cada modelo. Cuarto: Autocorrelograma para los residuos. **Columnas III y IV** Primero: Autocorrelograma para el cuadrado de los residuos. Segundo: Curva de impacto de noticias. Tercero: Gráfico de dispersión de la volatilidad predicha un paso hacia adelante y la volatilidad histórica estimada según Parkinson. Cuarto: Gráfico de retornos observados y Value At Risk al 1% predicho en el momento anterior. En rojo, aquellos retornos que exceden el límite estimado. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (APBR)

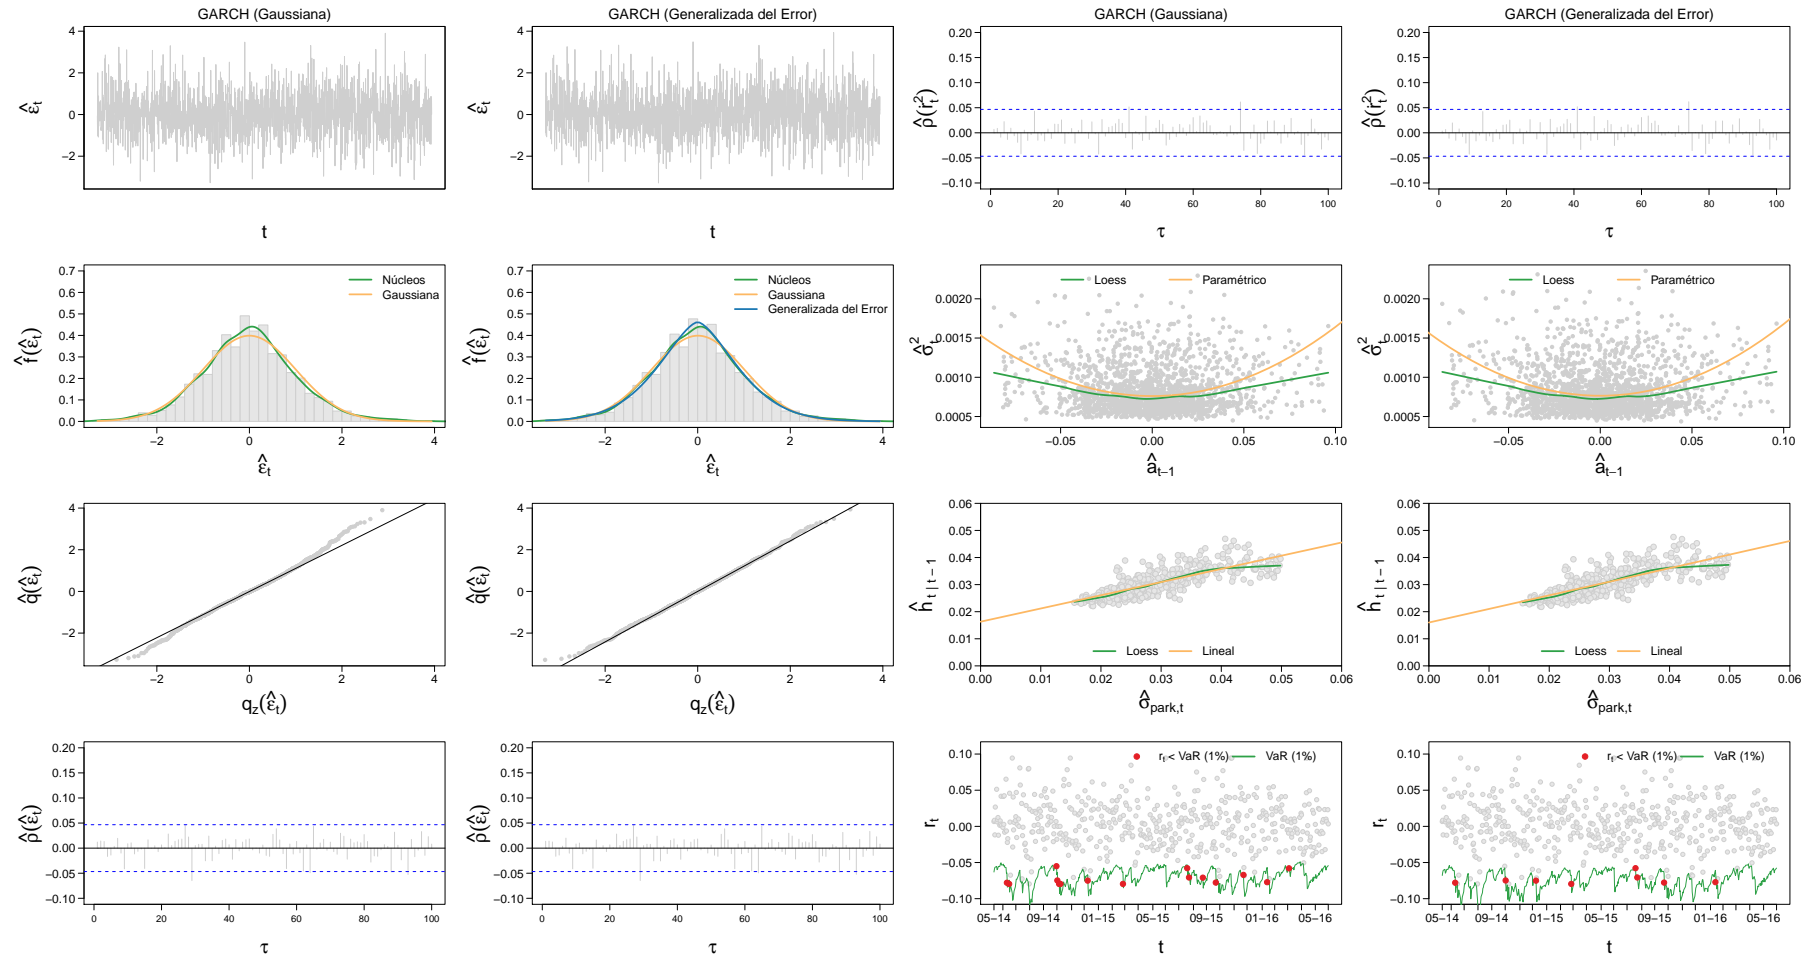
	Modelo base	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10
Especificación	GARCH	eGARCH	GARCH	GJRGARCH	TGARCH	eGARCH	GARCH	NGARCH	GJRGARCH	TGARCH	NGARCH
Densidad	norm	std	std	std	std	sstd	sstd	std	sstd	sstd	sstd
<b>Panel A: Diagnóstico de residuos</b>											
Mínimo	-4.4870	-4.5060	-4.6740	-4.6100	-4.4670	-4.5070	-4.6800	-4.5870	-4.6100	-4.4680	-4.6260
Máximo	4.2990	4.6560	4.3320	4.0220	4.8140	4.6560	4.3360	4.6070	4.0270	4.8140	4.5620
Media	-0.0088	-0.0001	-0.0099	-0.0027	0.0001	0.0018	-0.0084	-0.0096	-0.0012	0.0006	-0.0086
Mediana	-0.0043	0.0076	-0.0026	0.0042	0.0055	0.0089	-0.0009	-0.0037	0.0056	0.0060	-0.0047
Desvío Estándar	1.0010	1.0030	1.0020	1.0030	1.0050	1.0030	1.0020	1.0030	1.0030	1.0050	1.0030
Asimetría	-0.0853	-0.0879	-0.1085	-0.1029	-0.0496	-0.0885	-0.1095	-0.0903	-0.1030	-0.0497	-0.0995
Curtosis	3.8960	4.1180	4.0320	3.9680	4.1460	4.1200	4.0340	4.0810	3.9680	4.1470	4.0710
$\chi^2$ Pearson (50)	46.9800	42.9500	57.1400	39.9900	43.4000	42.9500	55.2700	52.0300	42.4900	45.3900	43.2900
p-valor	0.5555	0.7158	0.1984	0.8170	0.6987	0.7158	0.2499	0.3567	0.7326	0.6203	0.7030
AIC	-4.3470	<u>-4.3660</u>	-4.3630	-4.3640	-4.3640	-4.3650	-4.3620	-4.3620	-4.3630	-4.3630	-4.3620
BIC	-4.3280	<u>-4.3410</u>	-4.3390	-4.3390	-4.3390	-4.3370	-4.3370	-4.3370	-4.3350	-4.3350	-4.3340
Jarque-Bera	61.0200	94.0100	81.5500	71.8600	97.1200	94.3900	82.0300	88.0800	71.8100	97.1900	87.0900
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	4.4870	6.7320	5.8370	6.0730	6.8080	6.7970	5.9060	6.0940	6.1230	6.8210	5.4290
p-valor	0.9227	0.7505	0.8287	0.8091	0.7434	0.7445	0.8231	0.8073	0.8048	0.7423	0.8608
$z^2$ Ljung-Box (10)	9.2120	9.1260	12.4740	8.5740	9.2470	9.1820	12.5350	11.7140	8.5800	9.2560	12.7620
p-valor	0.5121	0.5202	0.2546	0.5729	0.5088	0.5150	0.2508	0.3047	0.5723	0.5080	0.2373
Ljung-Box (22)	17.3300	18.5700	18.6300	17.9800	19.0400	18.6300	18.6900	18.9200	18.0400	19.0500	18.0000
p-valor	0.7451	0.6715	0.6683	0.7069	0.6430	0.6681	0.6646	0.6502	0.7038	0.6424	0.7060
$z^2$ Ljung-Box (22)	24.1900	29.1900	29.1400	22.8400	29.5900	29.2300	29.2200	30.5600	22.8300	29.5900	30.9500
p-valor	0.3373	0.1395	0.1408	0.4107	0.1287	0.1384	0.1386	0.1055	0.4115	0.1287	0.0971
Sesgo del signo	2.1929	0.6913	1.4682	0.9148	0.4378	0.7150	0.7424	1.4295	0.9072	0.4362	2.2930
p-valor	0.0284	0.4894	0.1422	0.3604	0.6616	0.4747	0.4579	0.1530	0.3644	0.6627	0.0220
Sesgo de tamaño negativo	1.2118	1.0380	0.8959	0.8528	1.0441	1.0519	0.5232	1.0427	0.8431	1.0438	1.5370
p-valor	0.2257	0.2994	0.3704	0.3939	0.2966	0.2930	0.6009	0.2972	0.3993	0.2967	0.1245
Sesgo de tamaño positivo	0.1904	0.5311	0.2633	0.3966	0.7834	0.5173	0.6485	0.4116	0.3950	0.7828	0.0245
p-valor	0.8490	0.5955	0.7924	0.6917	0.4335	0.6050	0.5167	0.6807	0.6929	0.4338	0.9805
Efecto conjunto	6.2340	1.7660	3.7350	1.8910	1.9110	1.7990	2.1410	3.9490	1.8670	1.9080	7.2390
p-valor	0.1008	0.6224	0.2916	0.5953	0.5911	0.6152	0.5437	0.2671	0.6005	0.5917	0.0646
<b>Panel B: Evaluación de pronósticos</b>											
Hit <sup>-</sup>	0.0800	0.0600	0.0720	0.0840	0.0560	0.0600	0.0720	0.0760	0.0840	0.0560	0.0760
Hit <sup>+</sup>	0.9317	0.9679	0.9398	0.9438	0.9719	0.9639	0.9398	0.9478	0.9438	0.9719	0.9478
MCPDC	0.5050	0.5130	0.5050	0.5130	0.5130	0.5110	0.5130	0.5110	0.5130	0.5130	0.5110
QLIKE	-2.4370	-2.4300	-2.4320	-2.4320	-2.4280	-2.4300	-2.4310	-2.4310	-2.4320	-2.4280	-2.4310
$R^2$	0.5405	0.5396	0.5110	0.5215	0.5456	0.5380	0.5088	0.5130	0.5185	0.5453	0.5095
RMSE	0.0113	0.0127	0.0121	0.0122	0.0131	0.0128	0.0121	0.0123	0.0122	0.0131	0.0123
VaR excesos esperados	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000
VaR excesos observados	3.0000	0.0000	1.0000	0.0000	0.0000	0.0000	1.0000	2.0000	0.0000	0.0000	2.0000
VaR coeficiente de excesos	0.6000	0.0000	0.2000	0.0000	0.0000	0.0000	0.2000	0.4000	0.0000	0.0000	0.4000

**Cuadro B.1:** Estadísticos resumen de los residuos y los pronósticos correspondientes a distintos modelos aplicados a APBR (retornos truncados al 1%). Las densidades (s)norm, (s)std y (s)ged corresponden a las distribuciones gaussianas, t de Student y generalizada del error respectivamente, donde s hace referencia a la parametrización asimétrica. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (BMA)



**Figura B.2:** Diagnóstico de residuos y evaluación de pronósticos para BMA (retornos truncados al 1%).  
**Columnas I y III** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución gaussiana. **Columnas II y IV** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución generalizada del error asimétrica. **Columnas I y II** Primero: Serie de residuos estandarizados. Segundo: Histograma de los residuos estandarizados. Tercero: Gráfico de cuantil-cuantil de los residuos para la distribución supuesta por cada modelo. Cuarto: Autocorrelograma para los residuos. **Columnas III y IV** Primero: Autocorrelograma para el cuadrado de los residuos. Segundo: Curva de impacto de noticias. Tercero: Gráfico de dispersión de la volatilidad predicha un paso hacia adelante y la volatilidad histórica estimada según Parkinson. Cuarto: Gráfico de retornos observados y *Value At Risk* al 1% predicho en el momento anterior. En rojo, aquellos retornos que exceden el límite estimado. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (BMA)

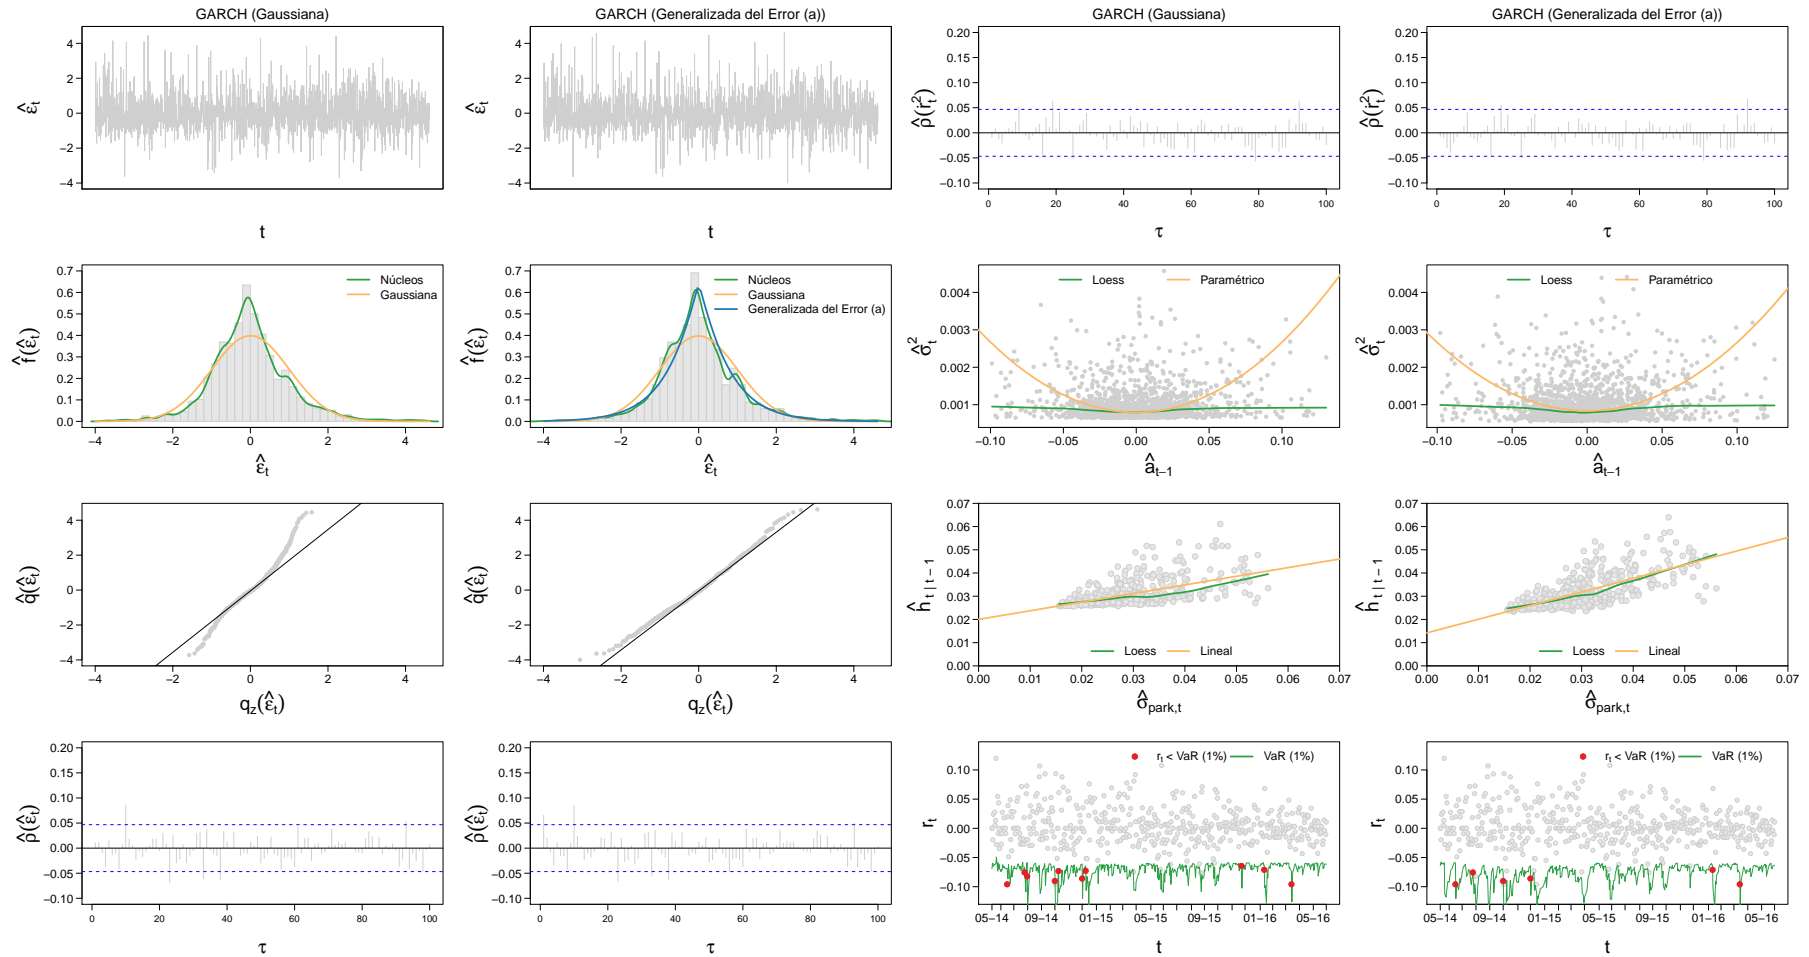
	Modelo base	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10
Especificación	GARCH	GARCH	GARCH	NGARCH	GJRGARCH	eGARCH	TGARCH	NGARCH	GJRGARCH	eGARCH	TGARCH
Densidad	norm	ged	sged	ged	ged	ged	ged	sged	sged	sged	sged
<b>Panel A: Diagnóstico de residuos</b>											
Mínimo	-3.2730	-3.2850	-3.2830	-3.2850	-3.2870	-3.3880	-3.3420	-3.2840	-3.2870	-3.3990	-3.3540
Máximo	3.9000	3.9380	3.9170	3.9370	3.9400	3.8310	3.8230	3.9160	3.9200	3.8050	3.7970
Media	-0.0005	0.0049	-0.0031	0.0049	0.0048	0.0013	0.0010	-0.0031	-0.0033	-0.0067	-0.0070
Mediana	-0.0160	-0.0118	-0.0196	-0.0118	-0.0118	-0.0145	-0.0141	-0.0195	-0.0196	-0.0227	-0.0233
Desvío Estándar	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0010	1.0000	1.0000	1.0000	1.0010
Asimetría	0.1241	0.1247	0.1253	0.1246	0.1246	0.1251	0.1256	0.1252	0.1251	0.1256	0.1259
Curtosis	3.5570	3.5670	3.5670	3.5660	3.5670	3.5640	3.5620	3.5670	3.5670	3.5650	3.5630
$\chi^2$ Pearson (50)	94.2800	76.0500	70.1500	75.2600	76.5100	77.4200	73.1000	71.0600	72.6500	72.5300	67.4800
p-valor	0.0001	0.0079	0.0254	0.0093	0.0072	0.0060	0.0144	0.0214	0.0157	0.0161	0.0411
AIC	-4.2960	<u>-4.3090</u>	<u>-4.3090</u>	-4.3080	-4.3080	-4.3050	-4.3050	-4.3070	-4.3070	-4.3050	-4.3050
BIC	-4.2770	<u>-4.2870</u>	-4.2840	-4.2830	-4.2830	-4.2800	-4.2800	-4.2790	-4.2790	-4.2770	-4.2770
Jarque-Bera	27.3100	28.1300	28.2100	28.1000	28.1400	27.9500	27.8400	28.1800	28.2200	28.0500	27.9100
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	5.7590	5.7940	5.8210	5.7930	5.7930	5.9930	5.8730	5.8200	5.8230	6.0290	5.9130
p-valor	0.8351	0.8323	0.8301	0.8323	0.8323	0.8158	0.8258	0.8301	0.8299	0.8128	0.8225
$z^2$ Ljung-Box (10)	5.5530	5.5620	5.6180	5.5640	5.5580	5.2790	5.8560	5.6180	5.6080	5.2420	5.7550
p-valor	0.8513	0.8506	0.8463	0.8504	0.8509	0.8718	0.8272	0.8463	0.8470	0.8744	0.8354
Ljung-Box (22)	11.3100	11.2400	11.2900	11.2400	11.2400	11.6100	11.5000	11.2800	11.2800	11.6700	11.5500
p-valor	0.9701	0.9711	0.9704	0.9711	0.9712	0.9649	0.9669	0.9704	0.9705	0.9639	0.9659
$z^2$ Ljung-Box (22)	13.5500	13.5400	13.6900	13.5200	13.5400	12.8000	12.9100	13.6700	13.6800	12.9300	12.9400
p-valor	0.9165	0.9169	0.9123	0.9176	0.9170	0.9387	0.9356	0.9129	0.9124	0.9352	0.9347
Sesgo del signo	1.4550	1.5370	1.4670	1.5400	1.5330	1.7110	1.7340	1.4700	1.4600	1.6510	1.6290
p-valor	0.1458	0.1246	0.1427	0.1239	0.1256	0.0872	0.0830	0.1417	0.1443	0.0990	0.1035
Sesgo de tamaño negativo	0.6520	0.8169	0.8108	0.8211	0.8091	0.9085	0.8030	0.8160	0.7972	0.9365	0.8050
p-valor	0.5145	0.4141	0.4176	0.4117	0.4186	0.3637	0.4221	0.4146	0.4255	0.3492	0.4210
Sesgo de tamaño positivo	1.0932	0.9832	0.9368	0.9825	0.9753	1.0336	1.1427	0.9358	0.9234	0.9654	1.0520
p-valor	0.2745	0.3256	0.3490	0.3260	0.3296	0.3014	0.2533	0.3495	0.3559	0.3345	0.2929
Efecto conjunto	2.2500	2.4000	2.1910	2.4080	2.3840	2.9470	3.0710	2.2000	2.1660	2.7430	2.6980
p-valor	0.5221	0.4936	0.5338	0.4921	0.4966	0.3999	0.3808	0.5319	0.5388	0.4330	0.4406
<b>Panel B: Evaluación de pronósticos</b>											
Hit <sup>-</sup>	0.3711	0.3633	0.3711	0.3828	0.3633	0.3438	0.3203	0.3867	0.3711	0.3555	0.3281
Hit <sup>+</sup>	0.7397	0.7397	0.7355	0.7397	0.7397	0.7355	0.7438	0.7273	0.7314	0.7355	0.7397
MCPDC	0.5491	0.5451	0.5471	0.5551	0.5451	0.5331	0.5251	0.5511	0.5451	0.5391	0.5271
QLIKE	-2.5490	-2.5490	-2.5490	-2.5490	-2.5490	-2.5460	-2.5460	-2.5490	-2.5490	-2.5460	-2.5460
$R^2$	0.6159	0.6145	0.6121	0.6021	0.6038	0.5346	0.5271	0.5964	0.6010	0.5337	0.5276
RMSE	0.0053	0.0053	0.0053	0.0053	0.0053	0.0058	0.0058	0.0053	0.0053	0.0057	0.0058
VaR excesos esperados	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000
VaR excesos observados	15.0000	8.0000	12.0000	8.0000	10.0000	9.0000	9.0000	12.0000	12.0000	12.0000	12.0000
VaR coeficiente de excesos	3.0000	1.6000	2.4000	1.6000	2.0000	1.8000	1.8000	2.4000	2.4000	2.4000	2.4000

**Cuadro B.2:** Estadísticos resumen de los residuos y los pronósticos correspondientes a distintos modelos aplicados a BMA (retornos truncados al 1%). Las densidades (s)norm, (s)std y (s)ged corresponden a las distribuciones gaussiana, t de Student y generalizada del error respectivamente, donde s hace referencia a la parametrización asimétrica. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (COME)



**Figura B.3:** Diagnóstico de residuos y evaluación de pronósticos para COME (retornos truncados al 1%).  
**Columnas I y III** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución gaussiana. **Columnas II y IV** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución generalizada del error asimétrica. **Columnas I y II** Primero: Serie de residuos estandarizados. Segundo: Histograma de los residuos estandarizados. Tercero: Gráfico de cuantil-cuantil de los residuos para la distribución supuesta por cada modelo. Cuarto: Autocorrelograma para los residuos. **Columnas III y IV** Primero: Autocorrelograma para el cuadrado de los residuos. Segundo: Curva de impacto de noticias. Tercero: Gráfico de dispersión de la volatilidad predicha un paso hacia adelante y la volatilidad histórica estimada según Parkinson. Cuarto: Gráfico de retornos observados y *Value At Risk* al 1% predicho en el momento anterior. En rojo, aquellos retornos que exceden el límite estimado. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (COME)

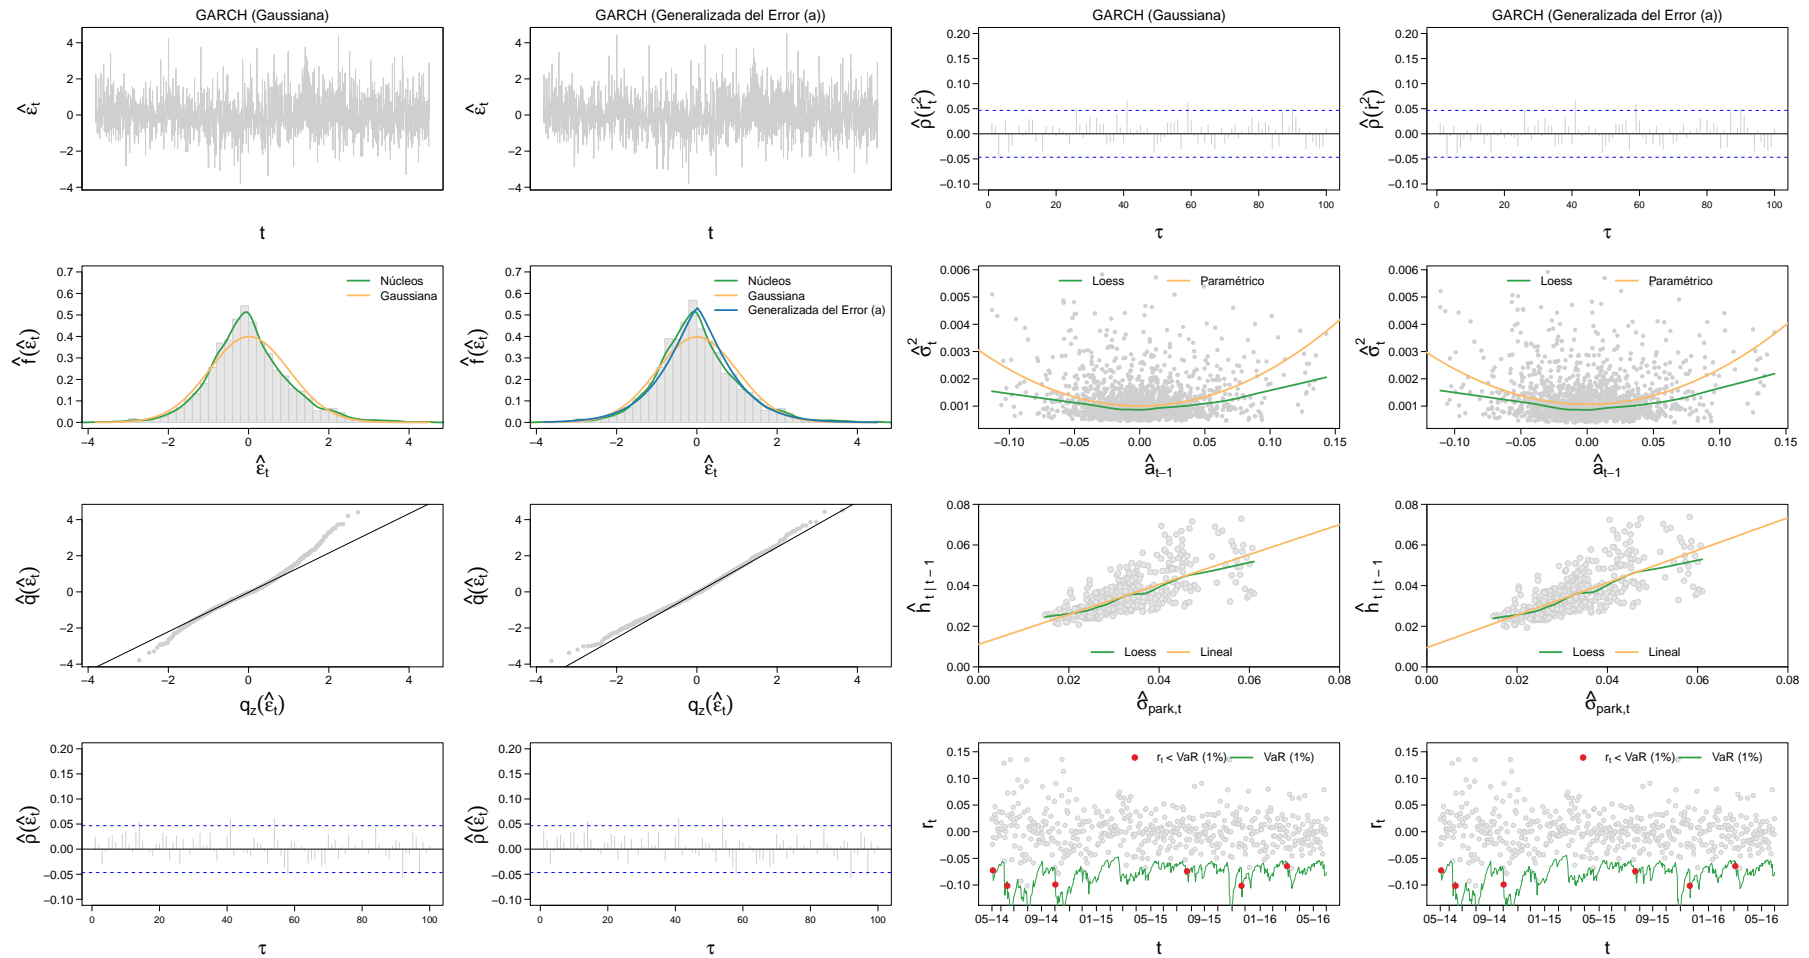
	Modelo base	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10
Especificación	GARCH	GARCH	GJRGARCH	GARCH	GJRGARCH	NGARCH	eGARCH	TGARCH	NGARCH	eGARCH	TGARCH
Densidad	norm	sged	sged	ged	ged	sged	sged	sged	ged	ged	ged
<b>Panel A: Diagnóstico de residuos</b>											
Mínimo	-3.7160	-3.9960	-4.0480	-3.8970	-3.9780	-4.0100	-4.2890	-4.2240	-3.9380	-4.3000	-4.2110
Máximo	4.4530	4.6210	4.7800	4.5790	4.7600	4.6190	4.7750	4.7190	4.5670	4.6840	4.6250
Media	0.0023	-0.0010	0.0073	0.0510	0.0604	-0.0007	0.0064	0.0063	0.0512	0.0634	0.0640
Mediana	-0.0544	-0.0614	-0.0542	0.0000	0.0034	-0.0610	-0.0545	-0.0549	0.0001	0.0051	0.0070
Desvío Estándar	1.0005	1.0033	1.0057	0.9970	0.9981	1.0033	1.0053	1.0052	0.9970	0.9979	0.9977
Asimetría	0.4695	0.4788	0.5173	0.4663	0.5128	0.4782	0.5077	0.5033	0.4642	0.4916	0.4853
Curtosis	5.0510	5.3090	5.3420	5.3350	5.3820	5.3080	5.3370	5.2990	5.3320	5.3770	5.3390
$\chi^2$ Pearson (50)	188.7000	76.3600	82.7800	107.3000	99.4500	80.5700	72.2600	74.2500	104.3400	113.1000	102.4100
p-valor	<0.0001	0.0074	0.0018	<0.0001	<0.0001	0.0030	0.0170	0.0114	<0.0001	<0.0001	<0.0001
AIC	-4.1560	-4.2650	<u>-4.2670</u>	-4.2600	-4.2610	-4.2640	-4.2640	-4.2630	-4.2590	-4.2590	-4.2580
BIC	-4.1370	<u>-4.2400</u>	-4.2390	-4.2380	-4.2370	-4.2360	-4.2360	-4.2350	-4.2340	-4.2340	-4.2330
Jarque-Bera	372.7000	457.8000	480.2000	463.1000	492.6000	457.0000	475.6000	461.5000	461.5000	484.8000	469.6000
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	19.9300	27.0400	27.9700	33.7500	33.5800	26.9600	27.7200	27.6800	33.7800	32.1000	31.5400
p-valor	0.0299	0.0026	0.0018	0.0002	0.0002	0.0026	0.0020	0.0020	0.0002	0.0004	0.0005
$z^2$ Ljung-Box (10)	6.9220	8.5070	7.3650	9.4330	8.1720	8.3410	5.8690	5.4760	9.0180	6.3590	5.7070
p-valor	0.7328	0.5794	0.6906	0.4916	0.6121	0.5956	0.8261	0.8572	0.5304	0.7842	0.8392
Ljung-Box (22)	25.0700	33.0000	33.4900	40.1300	39.4200	32.8900	33.2700	33.1400	40.1000	37.8700	37.1800
p-valor	0.2937	0.0619	0.0553	0.0104	0.0126	0.0634	0.0582	0.0599	0.0105	0.0190	0.0226
$z^2$ Ljung-Box (22)	24.1200	23.4400	20.5400	25.7100	22.0200	23.2100	18.4500	18.5500	24.9900	19.0200	18.8300
p-valor	0.3407	0.3773	0.5490	0.2645	0.4586	0.3897	0.6790	0.6731	0.2977	0.6439	0.6559
Sesgo del signo	0.5240	0.0975	0.1156	1.2901	0.9478	0.1413	0.0793	0.1374	1.2867	1.1234	1.1226
p-valor	0.6003	0.9223	0.9080	0.1972	0.3433	0.8877	0.9368	0.8908	0.1984	0.2614	0.2618
Sesgo de tamaño negativo	0.2979	0.2463	0.8303	0.2676	0.3898	0.2724	0.6241	0.6561	0.2749	0.0717	0.1358
p-valor	0.7658	0.8055	0.4065	0.7891	0.6967	0.7854	0.5327	0.5119	0.7834	0.9429	0.8920
Sesgo de tamaño positivo	0.5235	0.3080	0.3827	1.2875	0.2557	0.2871	0.4775	0.4653	1.2638	0.2112	0.3396
p-valor	0.6007	0.7581	0.7020	0.1981	0.7982	0.7741	0.6331	0.6418	0.2065	0.8327	0.7342
Efecto conjunto	0.3849	0.1954	1.3496	2.2950	2.4082	0.2085	1.0980	1.0346	2.2474	2.3628	2.3151
p-valor	0.9433	0.9783	0.7174	0.5135	0.4921	0.9762	0.7776	0.7929	0.5227	0.5006	0.5096
<b>Panel B: Evaluación de pronósticos</b>											
Hit <sup>-</sup>	0.4726	0.4473	0.4641	0.4346	0.4473	0.4473	0.4388	0.4473	0.4388	0.4219	0.4346
Hit <sup>+</sup>	0.6794	0.7366	0.7290	0.7290	0.7557	0.7405	0.7634	0.7748	0.7481	0.7901	0.7939
MCPDC	0.5812	0.5992	0.6032	0.5892	0.6092	0.6012	0.6092	0.6192	0.6012	0.6152	0.6232
QLIKE	-2.5170	-2.5220	-2.5220	-2.5160	-2.5190	-2.5220	-2.5220	-2.5210	-2.5170	-2.5200	-2.5190
$R^2$	0.2983	0.4701	0.4562	0.3309	0.3972	0.4681	0.4735	0.4604	0.3425	0.4333	0.4079
RMSE	0.0069	0.0063	0.0064	0.0075	0.0071	0.0063	0.0062	0.0063	0.0074	0.0066	0.0068
VaR excesos esperados	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000
VaR excesos observados	10.0000	6.0000	6.0000	5.0000	5.0000	6.0000	5.0000	6.0000	4.0000	3.0000	3.0000
VaR coeficiente de excesos	2.0000	1.2000	1.2000	1.0000	1.0000	1.2000	1.0000	1.2000	0.8000	0.6000	0.6000

**Cuadro B.3:** Estadísticos resumen de los residuos y los pronósticos correspondientes a distintos modelos aplicados a COME (retornos truncados al 1%). Las densidades (s)norm, (s)std y (s)ged corresponden a las distribuciones gaussiana, t de Student y generalizada del error respectivamente, donde s hace referencia a la parametrización asimétrica. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (EDN)



**Figura B.4:** Diagnóstico de residuos y evaluación de pronósticos para EDN (retornos truncados al 1%).  
**Columnas I y III** Modelo  $ARMA(1,1) - GARCH(1,1)$  con distribución gaussiana. **Columnas II y IV** Modelo  $ARMA(1,1) - GARCH(1,1)$  con distribución generalizada del error asimétrica. **Columnas I y II** Primero: Serie de residuos estandarizados. Segundo: Histograma de los residuos estandarizados. Tercero: Gráfico de cuantil-cuantil de los residuos para la distribución supuesta por cada modelo. Cuarto: Autocorrelograma para los residuos. **Columnas III y IV** Primero: Autocorrelograma para el cuadrado de los residuos. Segundo: Curva de impacto de noticias. Tercero: Gráfico de dispersión de la volatilidad predicha un paso hacia adelante y la volatilidad histórica estimada según Parkinson. Cuarto: Gráfico de retornos observados y *Value At Risk* al 1% predicho en el momento anterior. En rojo, aquellos retornos que exceden el límite estimado. Elaboración propia.



# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (EDN)

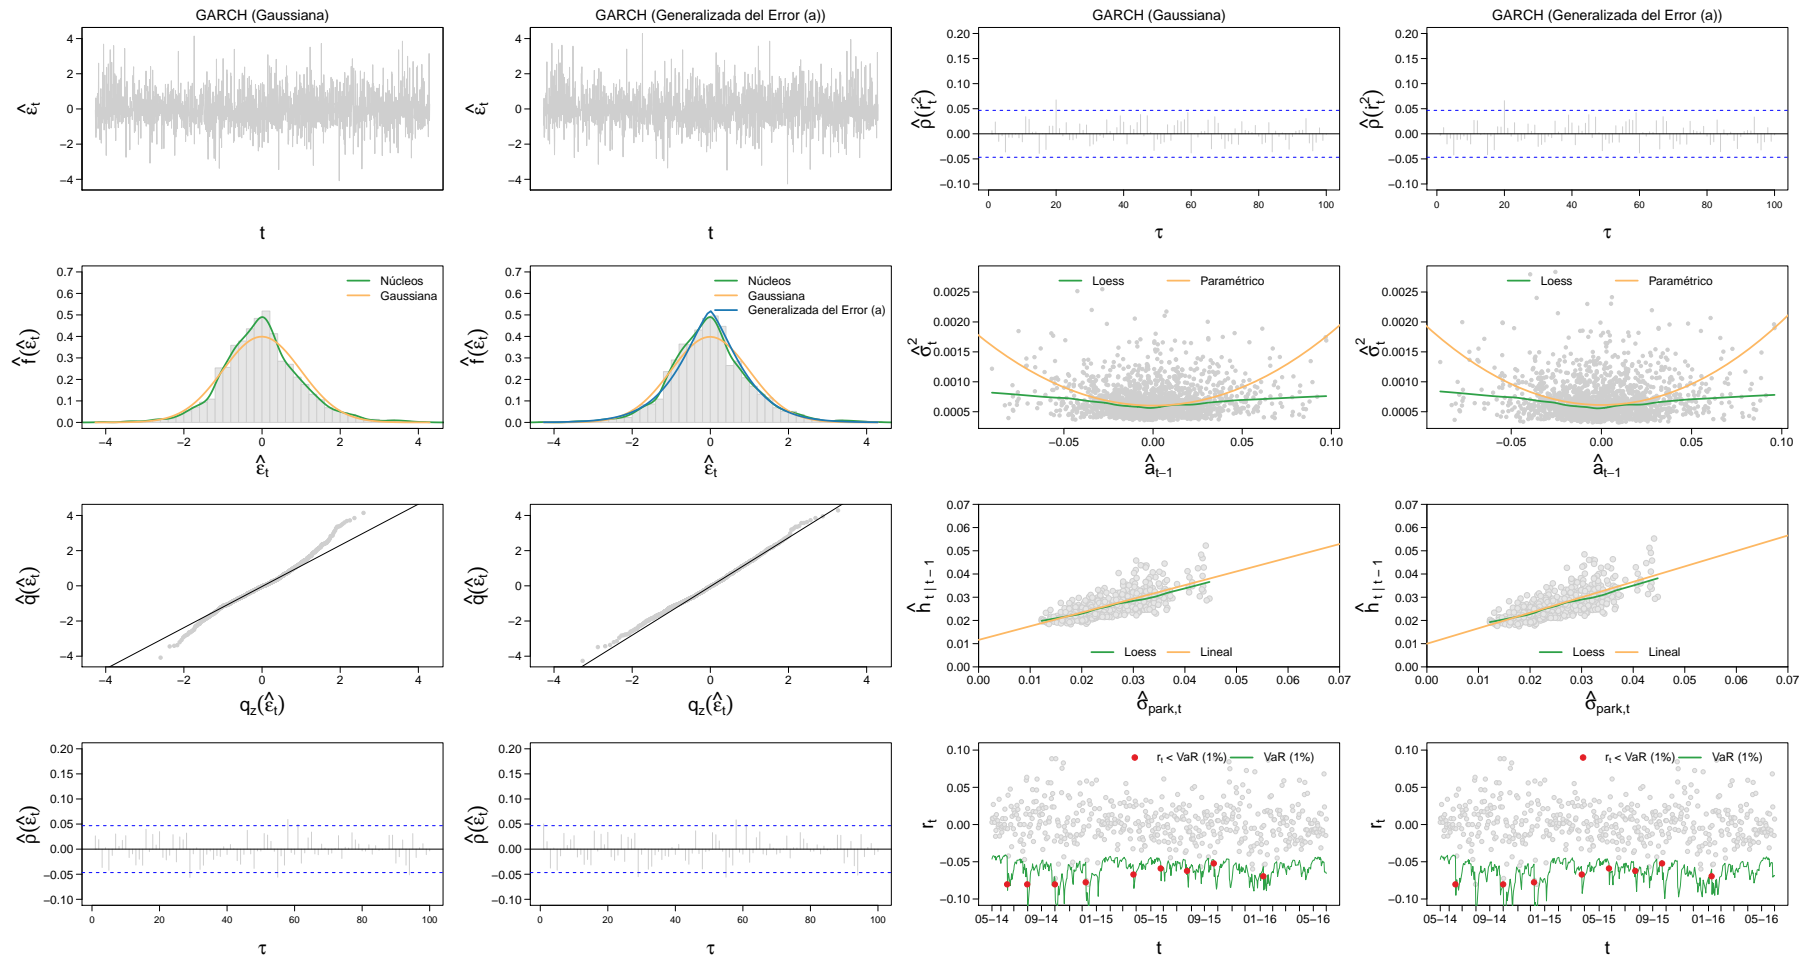
	Modelo base	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10
Especificación	GARCH	GARCH	GJRGARCH	NGARCH	GARCH	eGARCH	TGARCH	GJRGARCH	NGARCH	eGARCH	TGARCH
Densidad	norm	sged	sged	sged	sstd	sged	sged	sstd	sstd	sstd	sstd
<b>Panel A: Diagnóstico de residuos</b>											
Mínimo	-3.7840	-3.8190	-3.7850	-3.8290	-3.8260	-3.8490	-3.9290	-3.7830	-3.8560	-3.8510	-3.9320
Máximo	4.4070	4.5130	4.5890	4.4920	4.5120	5.1550	4.9860	4.5810	4.6580	5.3710	5.1590
Media	0.0120	0.0040	0.0074	0.0046	0.0059	0.0096	0.0102	0.0104	0.0078	0.0139	0.0135
Mediana	-0.0416	-0.0524	-0.0488	-0.0518	-0.0492	-0.0484	-0.0477	-0.0448	-0.0474	-0.0408	-0.0413
Desvío Estándar	1.0006	1.0034	1.0041	1.0036	0.9896	1.0050	1.0055	0.9908	0.9902	0.9921	0.9918
Asimetría	0.4055	0.4186	0.4312	0.4204	0.4236	0.4474	0.4328	0.4410	0.4298	0.4657	0.4462
Curtosis	4.2670	4.3740	4.4020	4.3840	4.4440	4.5510	4.5250	4.4840	4.4840	4.6970	4.6420
$\chi^2$ Pearson (50)	148.8600	67.9500	71.1400	72.2700	96.8200	57.6100	70.0000	82.1600	94.8900	61.8700	74.9400
p-valor	<0.0001	0.0378	0.0211	0.0169	<0.0001	0.1867	0.0261	0.0021	<0.0001	0.1025	0.0100
AIC	-4.0450	<u>-4.1060</u>	-4.1050	-4.1050	-4.1000	-4.1010	-4.1010	-4.0990	-4.0990	-4.0970	-4.0970
BIC	-4.0270	<u>-4.0810</u>	-4.0770	-4.0770	-4.0750	-4.0730	-4.0730	-4.0710	-4.0710	-4.0690	-4.0690
Jarque-Bera	165.9000	189.8000	198.7000	192.4000	205.6000	235.2000	225.5000	218.5000	215.6000	274.9000	256.1000
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	9.1000	11.0300	11.6400	11.1900	11.1000	12.1100	12.1600	11.8700	11.3500	11.9000	11.8800
p-valor	0.5227	0.3553	0.3096	0.3425	0.3500	0.2778	0.2743	0.2937	0.3311	0.2920	0.2932
$z^2$ Ljung-Box (10)	9.6520	10.3020	10.3220	10.1000	10.5490	8.3950	9.1830	10.4060	9.8110	7.7720	8.2220
p-valor	0.4716	0.4144	0.4127	0.4318	0.3937	0.5904	0.5149	0.4057	0.4573	0.6510	0.6072
Ljung-Box (22)	20.5900	22.6000	23.2700	22.7200	22.6500	23.2700	23.3100	23.4800	22.7200	22.8600	22.8500
p-valor	0.5463	0.4246	0.3868	0.4175	0.4216	0.3867	0.3843	0.3752	0.4175	0.4096	0.4105
$z^2$ Ljung-Box (22)	16.0600	14.9900	14.8300	14.7200	15.0000	12.8800	13.8700	14.5900	14.0600	11.8000	12.4900
p-valor	0.8131	0.8626	0.8696	0.8741	0.8623	0.9363	0.9061	0.8792	0.8993	0.9615	0.9465
Sesgo del signo	1.4220	1.4020	1.2740	1.3780	1.3370	1.3610	1.2400	1.1390	1.1730	1.2530	1.1530
p-valor	0.1551	0.1611	0.2027	0.1682	0.1813	0.1736	0.2150	0.2549	0.2410	0.2102	0.2491
Sesgo de tamaño negativo	0.9533	0.6482	0.3845	0.6012	0.3076	0.5488	0.4979	0.0558	0.1358	0.0580	0.0473
p-valor	0.3405	0.5169	0.7007	0.5478	0.7584	0.5832	0.6186	0.9555	0.8920	0.9538	0.9623
Sesgo de tamaño positivo	0.4111	0.2451	0.3948	0.2074	0.0852	0.1308	0.0174	0.1275	0.1347	0.2087	0.3155
p-valor	0.6810	0.8064	0.6930	0.8357	0.9321	0.8960	0.9861	0.8986	0.8929	0.8347	0.7524
Efecto conjunto	3.8670	3.5680	3.8440	3.3960	2.8700	3.1380	2.3620	3.2840	2.3260	2.7160	2.1020
p-valor	0.2762	0.3120	0.2788	0.3346	0.4121	0.3708	0.5007	0.3498	0.5075	0.4375	0.5516
<b>Panel B: Evaluación de pronósticos</b>											
Hit <sup>-</sup>	0.4206	0.4008	0.4087	0.4048	0.3889	0.3849	0.3968	0.3929	0.3889	0.3770	0.3730
Hit <sup>+</sup>	0.7724	0.7805	0.7846	0.7764	0.7967	0.7927	0.7602	0.7967	0.7967	0.7967	0.7967
MCPDC	0.5932	0.5872	0.5932	0.5872	0.5892	0.5852	0.5752	0.5912	0.5892	0.5832	0.5812
QLIKE	-2.4500	-2.4490	-2.4500	-2.4490	-2.4470	-2.4510	-2.4500	-2.4470	-2.4470	-2.4490	-2.4480
$R^2$	0.5040	0.5125	0.5207	0.5082	0.5138	0.5179	0.4942	0.5226	0.5094	0.5167	0.4928
RMSE	0.0077	0.0081	0.0081	0.0082	0.0089	0.0076	0.0079	0.0088	0.0090	0.0083	0.0087
VaR excesos esperados	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000
VaR excesos observados	6.0000	6.0000	6.0000	7.0000	5.0000	4.0000	5.0000	5.0000	5.0000	4.0000	4.0000
VaR coeficiente de excesos	1.2000	1.2000	1.2000	1.4000	1.0000	0.8000	1.0000	1.0000	1.0000	0.8000	0.8000

**Cuadro B.4:** Estadísticos resumen de los residuos y los pronósticos correspondientes a distintos modelos aplicados a EDN (retornos truncados al 1%). Las densidades (s)norm, (s)std y (s)ged corresponden a las distribuciones gaussiana, t de Student y generalizada del error respectivamente, donde s hace referencia a la parametrización asimétrica. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (ERAR)



**Figura B.5:** Diagnóstico de residuos y evaluación de pronósticos para ERAR (retornos truncados al 1%).  
**Columnas I y III** Modelo  $ARMA(1,1) - GARCH(1,1)$  con distribución gaussiana. **Columnas II y IV** Modelo  $ARMA(1,1) - GARCH(1,1)$  con distribución generalizada del error asimétrica. **Columnas I y II** Primero: Serie de residuos estandarizados. Segundo: Histograma de los residuos estandarizados. Tercero: Gráfico de cuantil-cuantil de los residuos para la distribución supuesta por cada modelo. Cuarto: Autocorrelograma para los residuos. **Columnas III y IV** Primero: Autocorrelograma para el cuadrado de los residuos. Segundo: Curva de impacto de noticias. Tercero: Gráfico de dispersión de la volatilidad predicha un paso hacia adelante y la volatilidad histórica estimada según Parkinson. Cuarto: Gráfico de retornos observados y *Value At Risk* al 1% predicho en el momento anterior. En rojo, aquellos retornos que exceden el límite estimado. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (ERAR)

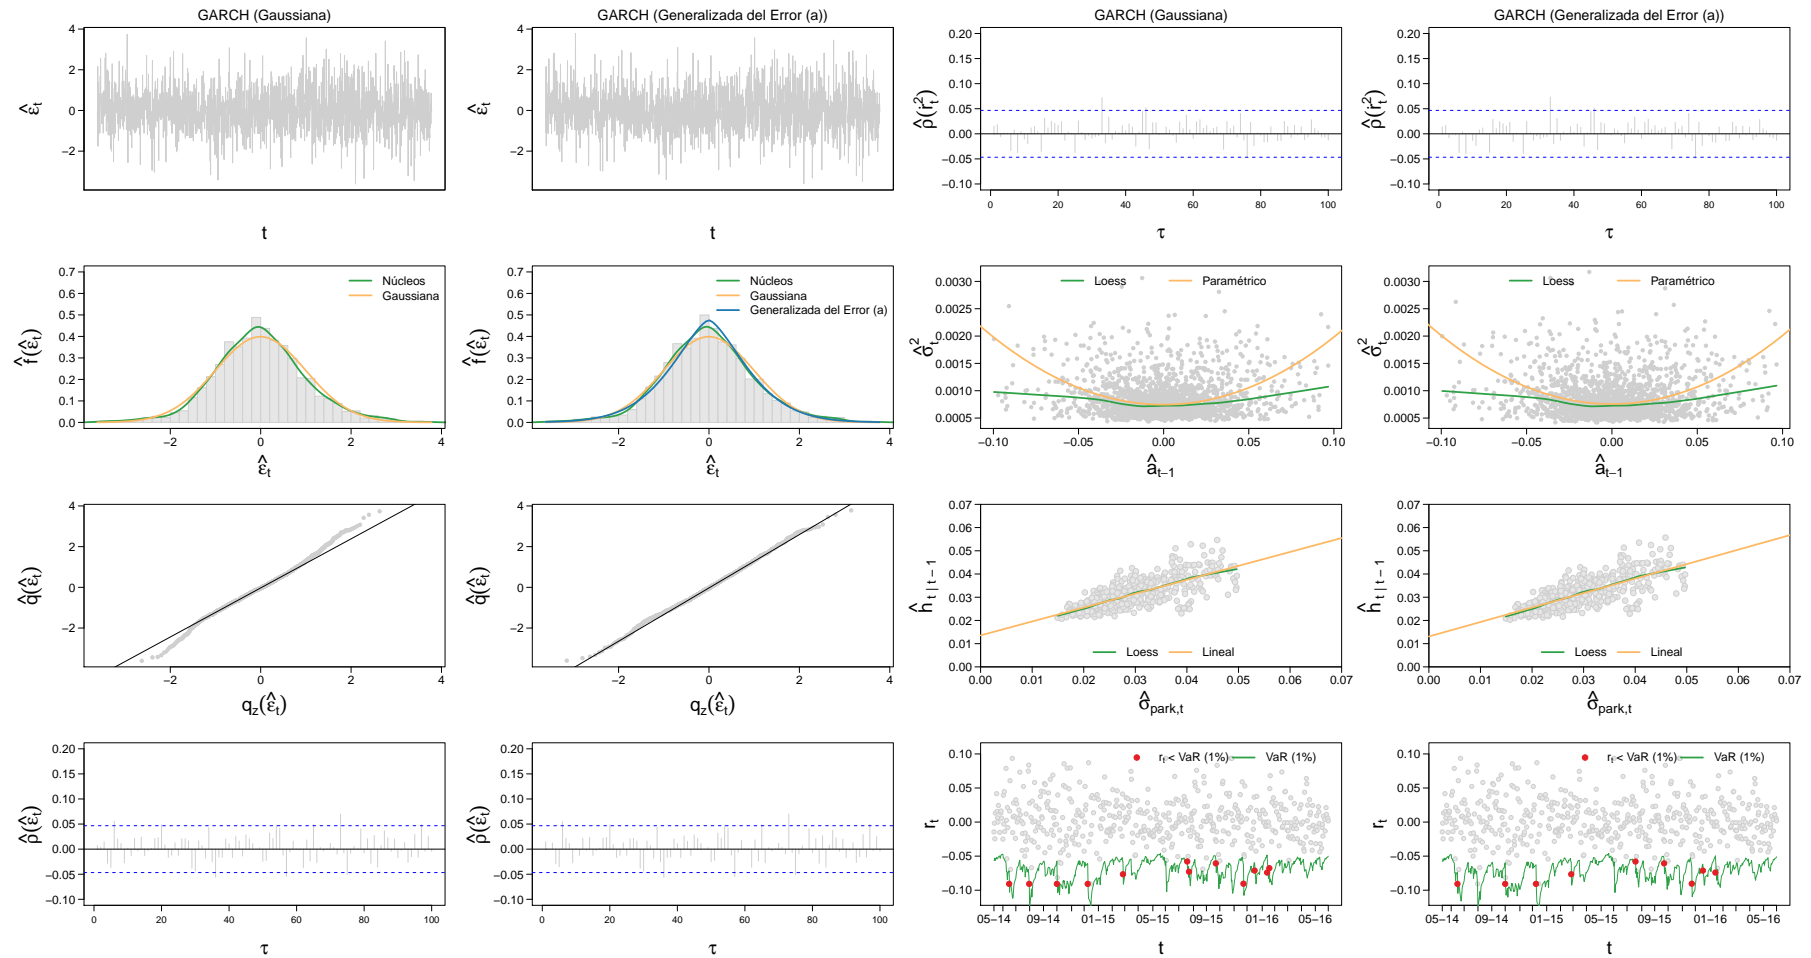
	Modelo base	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10
Especificación	GARCH	GARCH	GARCH	GJRGARCH	GJRGARCH	eGARCH	eGARCH	NGARCH	TGARCH	NGARCH	TGARCH
Densidad	norm	sged	sstd	sged	sstd	sged	sstd	sged	sged	sstd	sstd
<b>Panel A: Diagnóstico de residuos</b>											
Mínimo	-4.0820	-4.2650	-4.3110	-4.2550	-4.3090	-4.4250	-4.5000	-4.3180	-4.3470	-4.3590	-4.3980
Máximo	4.1450	4.2890	4.3440	4.2350	4.2810	4.2880	4.3360	4.3210	4.2550	4.3730	4.2910
Media	-0.0062	-0.0071	-0.0076	0.0015	0.0036	-0.0002	0.0012	-0.0068	0.0002	-0.0073	0.0016
Mediana	-0.0408	-0.0459	-0.0458	-0.0389	-0.0323	-0.0387	-0.0346	-0.0454	-0.0386	-0.0443	-0.0340
Desvío Estándar	0.9998	1.0019	0.9898	1.0032	0.9922	1.0029	0.9912	1.0020	1.0029	0.9900	0.9913
Asimetría	0.2811	0.2850	0.2908	0.2915	0.2984	0.2811	0.2864	0.2829	0.2759	0.2889	0.2802
Curtosis	4.2260	4.3210	4.3930	4.3520	4.4470	4.3720	4.4800	4.3270	4.3310	4.4000	4.4180
$\chi^2$ Pearson (50)	117.0200	56.9200	64.6000	57.0300	61.1300	44.5100	53.2200	54.3500	46.9600	65.1100	51.3400
p-valor	<0.0001	0.2042	0.0668	0.2013	0.1146	0.6556	0.3152	0.2779	0.5564	0.0614	0.3822
AIC	-4.5160	-4.5630	-4.5610	<u>-4.5640</u>	-4.5630	-4.5630	-4.5620	-4.5620	-4.5610	-4.5610	-4.5600
BIC	-4.4980	<u>-4.5380</u>	-4.5360	-4.5360	-4.5350	-4.5350	-4.5340	-4.5340	-4.5330	-4.5320	-4.5320
Jarque-Bera	133.1000	151.6000	166.9000	158.8000	179.3000	160.9000	184.4000	152.3000	152.0000	167.9000	170.2000
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	11.1300	14.5300	13.4000	15.3200	14.4800	14.9300	13.9600	14.4500	14.7100	13.3000	13.7100
p-valor	0.3478	0.1500	0.2023	0.1209	0.1523	0.1346	0.1750	0.1533	0.1428	0.2074	0.1865
$z^2$ Ljung-Box (10)	4.5280	5.7520	6.9580	4.3000	5.1060	3.1530	3.9170	5.5040	4.8020	6.6220	4.6040
p-valor	0.9204	0.8356	0.7294	0.9328	0.8840	0.9776	0.9510	0.8550	0.9040	0.7606	0.9160
Ljung-Box (22)	24.0700	26.7000	25.0800	26.9500	25.5300	26.8500	25.3200	26.5800	26.4800	24.9500	24.9500
p-valor	0.3436	0.2227	0.2931	0.2133	0.2722	0.2169	0.2819	0.2278	0.2318	0.2995	0.2994
$z^2$ Ljung-Box (22)	21.7100	21.8300	22.7500	20.0100	20.4100	19.5900	19.8600	21.5000	20.7400	22.3500	20.2400
p-valor	0.4773	0.4699	0.4157	0.5824	0.5574	0.6084	0.5918	0.4898	0.5370	0.4391	0.5683
Sesgo del signo	0.4913	0.3731	0.5972	0.5504	0.7466	0.3333	0.4313	0.3740	0.2853	0.5963	0.4029
p-valor	0.6233	0.7091	0.5505	0.5821	0.4554	0.7390	0.6663	0.7085	0.7755	0.5511	0.6871
Sesgo de tamaño negativo	0.0564	0.2542	0.8045	1.0231	1.6787	1.0905	1.7390	0.2906	0.7158	0.8348	1.3141
p-valor	0.9550	0.7994	0.4212	0.3064	0.0934	0.2757	0.0822	0.7714	0.4742	0.4039	0.1890
Sesgo de tamaño positivo	0.1217	0.5726	0.8813	0.1277	0.4224	0.4337	0.8018	0.5759	0.0637	0.8837	0.3555
p-valor	0.9032	0.5670	0.3783	0.8984	0.6728	0.6645	0.4228	0.5647	0.9492	0.3770	0.7223
Efecto conjunto	0.7896	1.0305	2.2976	1.0733	3.0027	1.3789	3.6877	1.0150	0.5261	2.3089	1.8885
p-valor	0.8520	0.7939	0.5130	0.7835	0.3912	0.7105	0.2972	0.7976	0.9131	0.5108	0.5959
<b>Panel B: Evaluación de pronósticos</b>											
Hit <sup>-</sup>	0.3852	0.3730	0.3689	0.3770	0.3689	0.4303	0.4057	0.3770	0.4098	0.3770	0.3648
Hit <sup>+</sup>	0.7137	0.7333	0.7725	0.7412	0.7686	0.7373	0.7412	0.7451	0.7490	0.7647	0.7569
MCPDC	0.5531	0.5571	0.5752	0.5631	0.5731	0.5872	0.5772	0.5651	0.5832	0.5752	0.5651
QLIKE	-2.7060	-2.7060	-2.7040	-2.7050	-2.7020	-2.7030	-2.7010	-2.7060	-2.7040	-2.7040	-2.7020
$R^2$	0.5315	0.5323	0.5110	0.5060	0.4767	0.4344	0.4133	0.5302	0.4878	0.5105	0.4686
RMSE	0.0049	0.0051	0.0056	0.0053	0.0058	0.0055	0.0059	0.0051	0.0052	0.0055	0.0056
VaR excesos esperados	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000
VaR excesos observados	9.0000	8.0000	8.0000	8.0000	8.0000	6.0000	8.0000	8.0000	7.0000	8.0000	7.0000
VaR coeficiente de excesos	1.8000	1.6000	1.6000	1.6000	1.6000	1.2000	1.6000	1.6000	1.4000	1.6000	1.4000

**Cuadro B.5:** Estadísticos resumen de los residuos y los pronósticos correspondientes a distintos modelos aplicados a ERAR (retornos truncados al 1%). Las densidades (s)norm, (s)std y (s)ged corresponden a las distribuciones gaussiana, t de Student y generalizada del error respectivamente, donde s hace referencia a la parametrización asimétrica. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (FRAN)



**Figura B.6:** Diagnóstico de residuos y evaluación de pronósticos para FRAN (retornos truncados al 1%).  
**Columnas I y III** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución gaussiana. **Columnas II y IV** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución generalizada del error asimétrica. **Columnas I y II** Primero: Serie de residuos estandarizados. Segundo: Histograma de los residuos estandarizados. Tercero: Gráfico de cuantil-cuantil de los residuos para la distribución supuesta por cada modelo. Cuarto: Autocorrelograma para los residuos. **Columnas III y IV** Primero: Autocorrelograma para el cuadrado de los residuos. Segundo: Curva de impacto de noticias. Tercero: Gráfico de dispersión de la volatilidad predicha un paso hacia adelante y la volatilidad histórica estimada según Parkinson. Cuarto: Gráfico de retornos observados y *Value At Risk* al 1% predicho en el momento anterior. En rojo, aquellos retornos que exceden el límite estimado. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (FRAN)

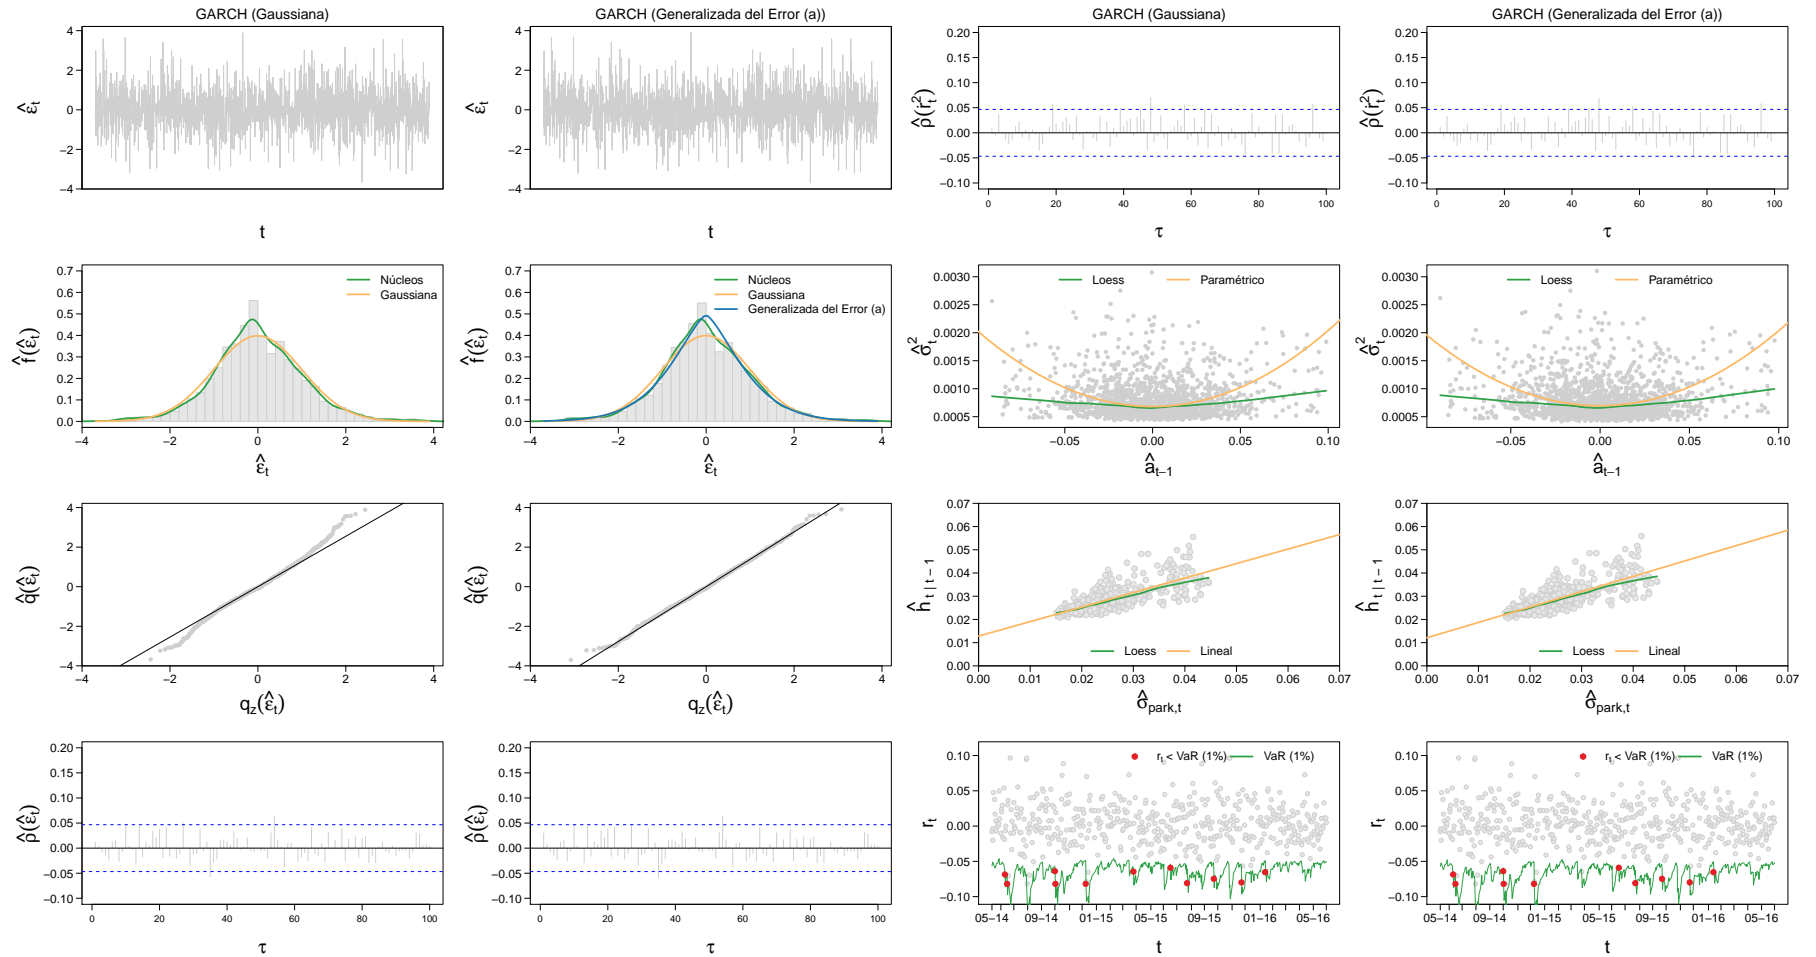
	Modelo base	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10
Especificación	GARCH	GARCH	GARCH	NGARCH	GJRGARCH	NGARCH	GJRGARCH	eGARCH	eGARCH	TGARCH	TGARCH
Densidad	norm	sged	sstd	sged	sged	sstd	sstd	sged	sstd	sged	sstd
<b>Panel A: Diagnóstico de residuos</b>											
Mínimo	-3.6130	-3.6020	-3.5960	-3.4940	-3.6720	-3.4720	-3.6720	-3.6830	-3.6910	-3.6860	-3.6670
Máximo	3.7360	3.7830	3.7890	3.7210	3.7970	3.7540	3.8050	3.8150	3.8100	3.7830	3.8170
Media	-0.0029	-0.0036	-0.0066	-0.0025	0.0008	-0.0063	-0.0013	-0.0026	-0.0053	-0.0024	-0.0051
Mediana	-0.0453	-0.0425	-0.0470	-0.0441	-0.0381	-0.0489	-0.0421	-0.0435	-0.0449	-0.0427	-0.0452
Desvío Estándar	1.0009	1.0006	0.9968	0.9996	1.0010	0.9955	0.9973	1.0007	0.9967	1.0011	0.9970
Asimetría	0.1134	0.1176	0.1181	0.1248	0.1207	0.1261	0.1222	0.1162	0.1209	0.1094	0.1133
Curtosis	3.7080	3.7230	3.7320	3.7190	3.7320	3.7270	3.7450	3.7640	3.7830	3.7690	3.7870
$\chi^2$ Pearson (50)	89.4000	44.7100	62.0300	44.9300	50.2200	60.1000	57.9400	45.5000	37.1000	37.8900	42.3800
p-valor	0.0004	0.6477	0.1002	0.6386	0.4250	0.1330	0.1789	0.6157	0.8939	0.8752	0.7368
AIC	-4.2940	<u>-4.3140</u>	-4.3120	<u>-4.3140</u>	-4.3130	-4.3130	-4.3120	-4.3070	-4.3050	-4.3050	-4.3030
BIC	-4.2750	<u>-4.2890</u>	-4.2870	-4.2860	-4.2850	-4.2850	-4.2840	-4.2790	-4.2770	-4.2770	-4.2750
Jarque-Bera	40.5500	42.4300	43.4400	42.5000	43.6100	43.4500	45.1100	46.7600	49.2800	46.9100	49.2200
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	12.0100	12.0800	11.8500	11.9200	12.0800	11.5700	11.8900	12.5000	12.9800	12.3500	12.7000
p-valor	0.2844	0.2797	0.2954	0.2905	0.2797	0.3148	0.2928	0.2530	0.2249	0.2623	0.2407
$z^2$ Ljung-Box (10)	5.8570	6.6210	6.6690	6.8420	6.4260	7.3880	6.4920	7.5290	7.3770	9.7280	9.3350
p-valor	0.8271	0.7607	0.7563	0.7402	0.7783	0.6884	0.7724	0.6748	0.6894	0.4647	0.5006
Ljung-Box (22)	21.0400	21.1600	21.0000	21.0800	21.3100	20.7500	21.2200	21.3400	22.1100	20.9600	21.5600
p-valor	0.5181	0.5108	0.5210	0.5160	0.5014	0.5361	0.5074	0.4999	0.4535	0.5229	0.4865
$z^2$ Ljung-Box (22)	15.1500	15.5700	15.7000	15.6900	16.3400	16.2500	16.5700	18.1000	17.9000	19.9200	19.3700
p-valor	0.8557	0.8369	0.8306	0.8309	0.7987	0.8033	0.7869	0.7003	0.7121	0.5879	0.6224
Sesgo del signo	0.3781	0.4316	0.4598	0.4532	0.6478	0.4147	0.6223	0.8231	0.9034	0.7868	0.7762
p-valor	0.7054	0.6661	0.6457	0.6505	0.5172	0.6784	0.5338	0.4106	0.3665	0.4315	0.4377
Sesgo de tamaño negativo	0.5512	0.7062	0.8510	0.6268	1.0920	0.7688	1.2362	1.0148	1.2325	0.7445	0.9031
p-valor	0.5815	0.4802	0.3949	0.5309	0.2750	0.4421	0.2166	0.3103	0.2179	0.4567	0.3666
Sesgo de tamaño positivo	0.0973	0.0083	0.0989	0.0977	0.3176	0.0734	0.2049	0.5433	0.4814	0.7492	0.6396
p-valor	0.9225	0.9934	0.9212	0.9222	0.7508	0.9415	0.8377	0.5870	0.6303	0.4539	0.5225
Efecto conjunto	0.3160	0.5057	0.7431	0.4136	1.3177	0.6020	1.6178	1.3251	1.7510	1.1160	1.2305
p-valor	0.9570	0.9176	0.8630	0.9374	0.7249	0.8960	0.6554	0.7232	0.6257	0.7732	0.7457
<b>Panel B: Evaluación de pronósticos</b>											
Hit <sup>-</sup>	0.3558	0.3371	0.3184	0.3371	0.3521	0.3258	0.3333	0.3483	0.3296	0.3371	0.3071
Hit <sup>+</sup>	0.7845	0.7931	0.7931	0.8060	0.7716	0.8190	0.7759	0.7500	0.7672	0.7457	0.7629
MCPDC	0.5551	0.5491	0.5391	0.5551	0.5471	0.5551	0.5391	0.5351	0.5331	0.5271	0.5190
QLIKE	-2.5600	-2.5600	-2.5590	-2.5590	-2.5600	-2.5590	-2.5590	-2.5590	-2.5590	-2.5590	-2.5590
R <sup>2</sup>	0.5514	0.5584	0.5609	0.5522	0.5629	0.5539	0.5639	0.5490	0.5517	0.5484	0.5500
RMSE	0.0057	0.0057	0.0058	0.0059	0.0057	0.0059	0.0058	0.0056	0.0057	0.0057	0.0058
VaR excesos esperados	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000
VaR excesos observados	12.0000	9.0000	10.0000	9.0000	10.0000	9.0000	10.0000	11.0000	11.0000	11.0000	12.0000
VaR coeficiente de excesos	2.4000	1.8000	2.0000	1.8000	2.0000	1.8000	2.0000	2.2000	2.2000	2.2000	2.4000

**Cuadro B.6:** Estadísticos resumen de los residuos y los pronósticos correspondientes a distintos modelos aplicados a FRAN (retornos truncados al 1%). Las densidades (s)norm, (s)std y (s)ged corresponden a las distribuciones gaussiana, t de Student y generalizada del error respectivamente, donde s hace referencia a la parametrización asimétrica. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (GGAL)



**Figura B.7:** Diagnóstico de residuos y evaluación de pronósticos para GGAL (retornos truncados al 1%).  
**Columnas I y III** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución gaussiana. **Columnas II y IV** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución generalizada del error asimétrica. **Columnas I y II** Primero: Serie de residuos estandarizados. Segundo: Histograma de los residuos estandarizados. Tercero: Gráfico de cuantil-cuantil de los residuos para la distribución supuesta por cada modelo. Cuarto: Autocorrelograma para los residuos. **Columnas III y IV** Primero: Autocorrelograma para el cuadrado de los residuos. Segundo: Curva de impacto de noticias. Tercero: Gráfico de dispersión de la volatilidad predicha un paso hacia adelante y la volatilidad histórica estimada según Parkinson. Cuarto: Gráfico de retornos observados y *Value At Risk* al 1% predicho en el momento anterior. En rojo, aquellos que exceden el límite estimado. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (GGAL)

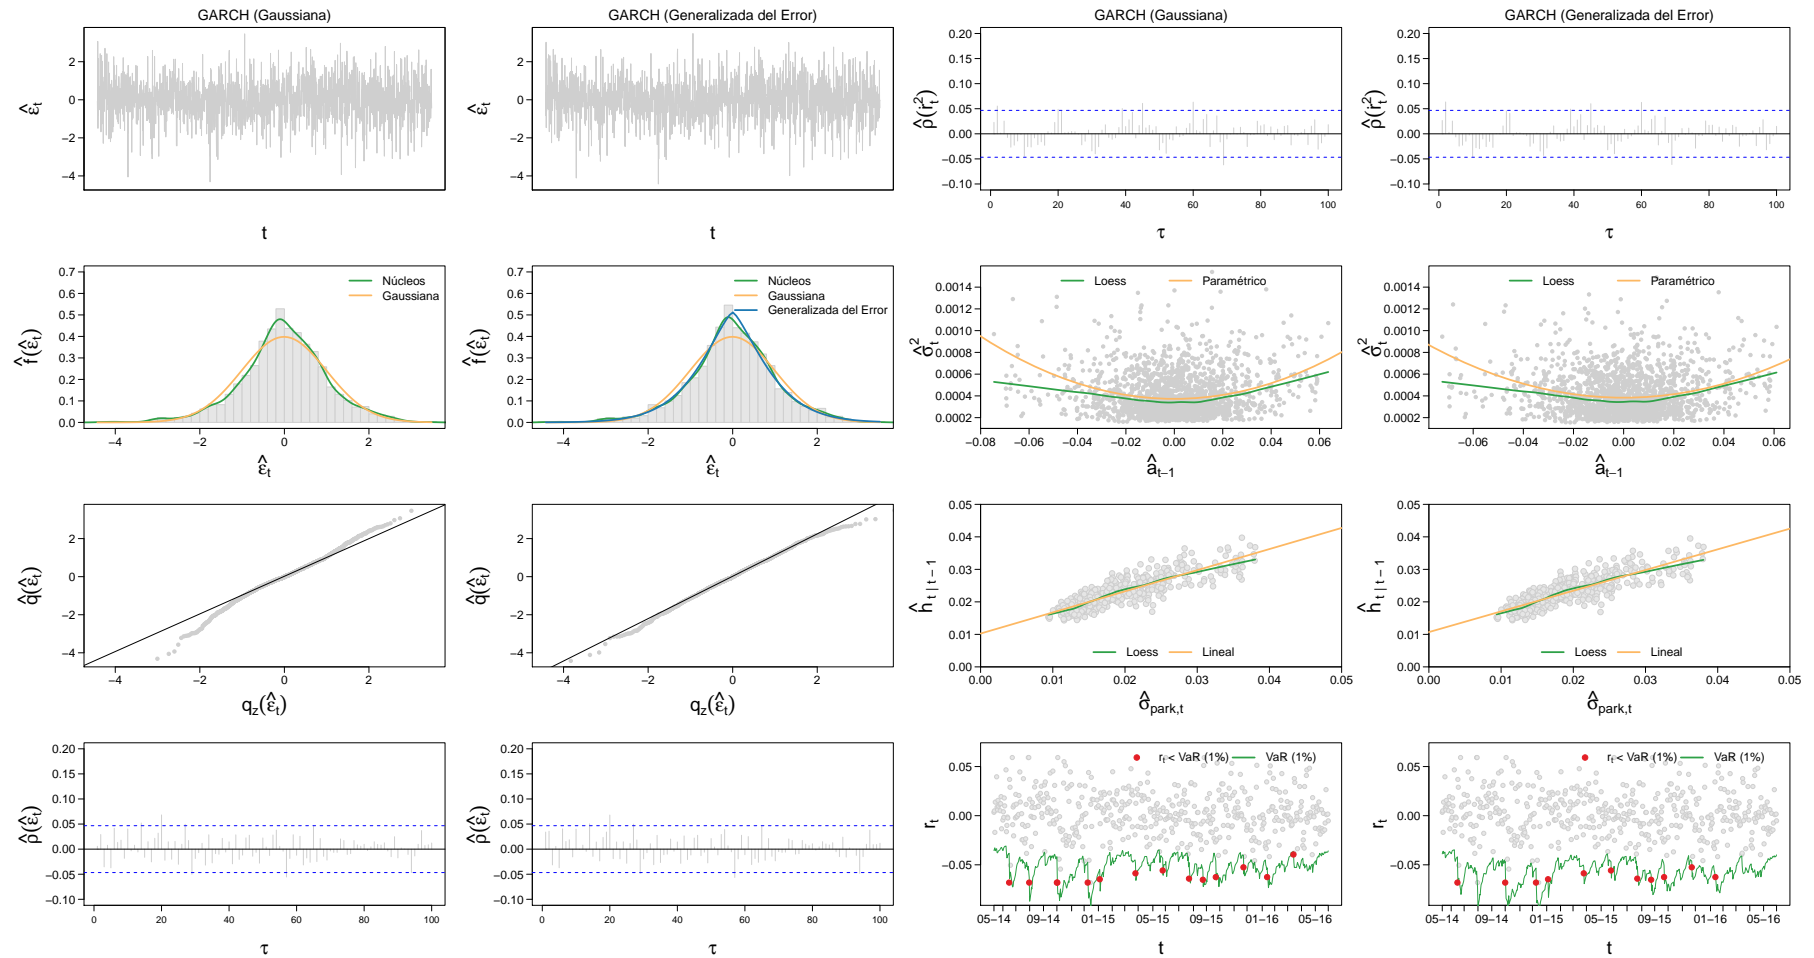
	Modelo base	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10
Especificación	GARCH	GARCH	GJRGARCH	NGARCH	GARCH	GJRGARCH	NGARCH	eGARCH	TGARCH	eGARCH	TGARCH
Densidad	norm	sged	sged	sged	sstd	sstd	sstd	sged	sged	sstd	sstd
<b>Panel A: Diagnóstico de residuos</b>											
Mínimo	-3.6720	-3.6980	-3.7100	-3.7010	-3.7380	-3.7460	-3.7640	-3.6770	-3.6510	-3.7090	-3.6820
Máximo	3.8910	3.9080	3.8180	3.9250	3.8980	3.7980	3.9390	3.8430	3.8100	3.8660	3.8410
Media	-0.0036	-0.0015	0.0058	-0.0032	-0.0072	0.0013	-0.0098	0.0061	0.0051	0.0016	0.0016
Mediana	-0.0596	-0.0579	-0.0518	-0.0609	-0.0577	-0.0533	-0.0670	-0.0534	-0.0545	-0.0574	-0.0573
Desvío Estándar	1.0013	0.9998	1.0006	1.0000	0.9958	0.9969	0.9993	1.0007	1.0010	0.9963	0.9964
Asimetría	0.1139	0.1079	0.1244	0.1046	0.1060	0.1233	0.1015	0.1303	0.1426	0.1307	0.1434
Curtosis	3.8600	3.8980	3.9030	3.8740	3.9230	3.9300	3.9070	3.9560	3.9810	3.9870	4.0130
$\chi^2$ Pearson (50)	96.2100	48.4500	58.5600	52.7100	56.7500	54.4200	62.0300	44.2000	46.3000	49.0800	39.9400
p-valor	<0.0001	0.4951	0.1646	0.3325	0.2086	0.2759	0.1002	0.6679	0.5834	0.4699	0.8187
AIC	-4.3630	-4.3890	<u>-4.3900</u>	<u>-4.3900</u>	-4.3860	-4.3870	-4.3870	-4.3860	-4.3830	-4.3830	-4.3800
BIC	-4.3440	<u>-4.3640</u>	-4.3620	-4.3620	-4.3610	-4.3590	-4.3590	-4.3580	-4.3550	-4.3550	-4.3520
Jarque-Bera	58.1400	62.6000	64.4000	59.2600	65.8200	67.9300	63.4100	72.1100	76.5200	76.4700	81.3400
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	7.9180	9.0210	9.1530	9.5170	8.7450	8.8540	9.4770	8.8600	8.6050	8.5780	8.2780
p-valor	0.6369	0.5301	0.5177	0.4838	0.5564	0.5460	0.4876	0.5455	0.5699	0.5725	0.6017
$z^2$ Ljung-Box (10)	5.4970	5.3250	5.1920	4.9830	5.6990	5.2690	5.2680	6.8150	8.6290	6.7080	8.6090
p-valor	0.8556	0.8685	0.8780	0.8923	0.8399	0.8725	0.8725	0.7428	0.5677	0.7527	0.5696
Ljung-Box (22)	22.9500	23.7100	24.6400	23.8600	23.3100	24.2800	23.7200	24.5000	24.3800	24.1700	24.0100
p-valor	0.4043	0.3625	0.3144	0.3545	0.3843	0.3326	0.3620	0.3217	0.3274	0.3382	0.3469
$z^2$ Ljung-Box (22)	16.4300	16.0600	15.1200	18.2400	16.6300	15.2600	18.1900	16.2100	18.0200	16.3800	18.3400
p-valor	0.7940	0.8130	0.8571	0.6914	0.7836	0.8507	0.6949	0.8054	0.7047	0.7967	0.6858
Sesgo del signo	0.8643	0.6888	0.4297	0.9160	0.7940	0.4354	1.0632	0.4567	0.3980	0.4699	0.4495
p-valor	0.3875	0.4910	0.6674	0.3598	0.4273	0.6633	0.2879	0.6480	0.6907	0.6385	0.6531
Sesgo de tamaño negativo	0.7425	0.6251	0.0654	0.7352	0.5972	0.1704	0.7371	0.2218	0.3480	0.0832	0.2685
p-valor	0.4579	0.5320	0.9478	0.4623	0.5505	0.8647	0.4611	0.8245	0.7279	0.9337	0.7884
Sesgo de tamaño positivo	0.6634	0.5810	0.0074	0.6330	0.6992	0.0572	0.7644	0.0916	0.2803	0.0061	0.1944
p-valor	0.5072	0.5613	0.9941	0.5268	0.4845	0.9544	0.4447	0.9270	0.7793	0.9952	0.8459
Efecto conjunto	1.0226	0.7333	0.5124	1.0235	0.8687	0.5925	1.2864	0.4195	0.5306	0.4393	0.5224
p-valor	0.7958	0.8653	0.9162	0.7956	0.8330	0.8981	0.7324	0.9362	0.9121	0.9320	0.9139
<b>Panel B: Evaluación de pronósticos</b>											
Hit <sup>-</sup>	0.2431	0.2431	0.2471	0.2824	0.2314	0.2314	0.2667	0.2157	0.2118	0.1882	0.1765
Hit <sup>+</sup>	0.8601	0.8601	0.8807	0.8642	0.8765	0.8848	0.8560	0.8724	0.8807	0.8807	0.8807
MCPDC	0.5431	0.5431	0.5551	0.5651	0.5451	0.5491	0.5351	0.5371	0.5251	0.5251	0.5190
QLIKE	-2.6870	-2.6870	-2.6870	-2.6870	-2.6860	-2.6860	-2.6870	-2.6860	-2.6860	-2.6850	-2.6850
$R^2$	0.5700	0.5938	0.5884	0.5501	0.6107	0.6022	0.5651	0.5987	0.6056	0.6106	0.6192
RMSE	0.0056	0.0057	0.0057	0.0059	0.0058	0.0059	0.0060	0.0057	0.0056	0.0058	0.0058
VaR excesos esperados	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000
VaR excesos observados	11.0000	10.0000	9.0000	9.0000	10.0000	9.0000	9.0000	8.0000	7.0000	8.0000	7.0000
VaR coeficiente de excesos	2.2000	2.0000	1.8000	1.8000	2.0000	1.8000	1.8000	1.6000	1.4000	1.6000	1.4000

**Cuadro B.7:** Estadísticos resumen de los residuos y los pronósticos correspondientes a distintos modelos aplicados a GGAL (retornos truncados al 1%). Las densidades (s)norm, (s)std y (s)ged corresponden a las distribuciones gaussiana, t de Student y generalizada del error respectivamente, donde s hace referencia a la parametrización asimétrica. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (MERVAL)



**Figura B.8:** Diagnóstico de residuos y evaluación de pronósticos para MERVAL (retornos truncados al 1 %). **Columnas I y III** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución gaussiana. **Columnas II y IV** Modelo  $ARMA(1, 1) - eGARCH(1, 1)$  con distribución generalizada del error. **Columnas I y II** Primer: Serie de residuos estandarizados. Segundo: Histograma de los residuos estandarizados. Tercero: Gráfico de cuantil-cuantil de los residuos para la distribución supuesta por cada modelo. Cuarto: Autocorrelograma para los residuos. **Columnas III y IV** Primer: Autocorrelograma para el cuadrado de los residuos. Segundo: Curva de impacto de noticias. Tercero: Gráfico de dispersión de la volatilidad predicha un paso hacia adelante y la volatilidad histórica estimada según Parkinson. Cuarto: Gráfico de retornos observados y *Value At Risk* al 1% predicho en el momento anterior. En rojo, aquellos retornos que exceden el límite estimado. Elaboración propia.



# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (Merval)

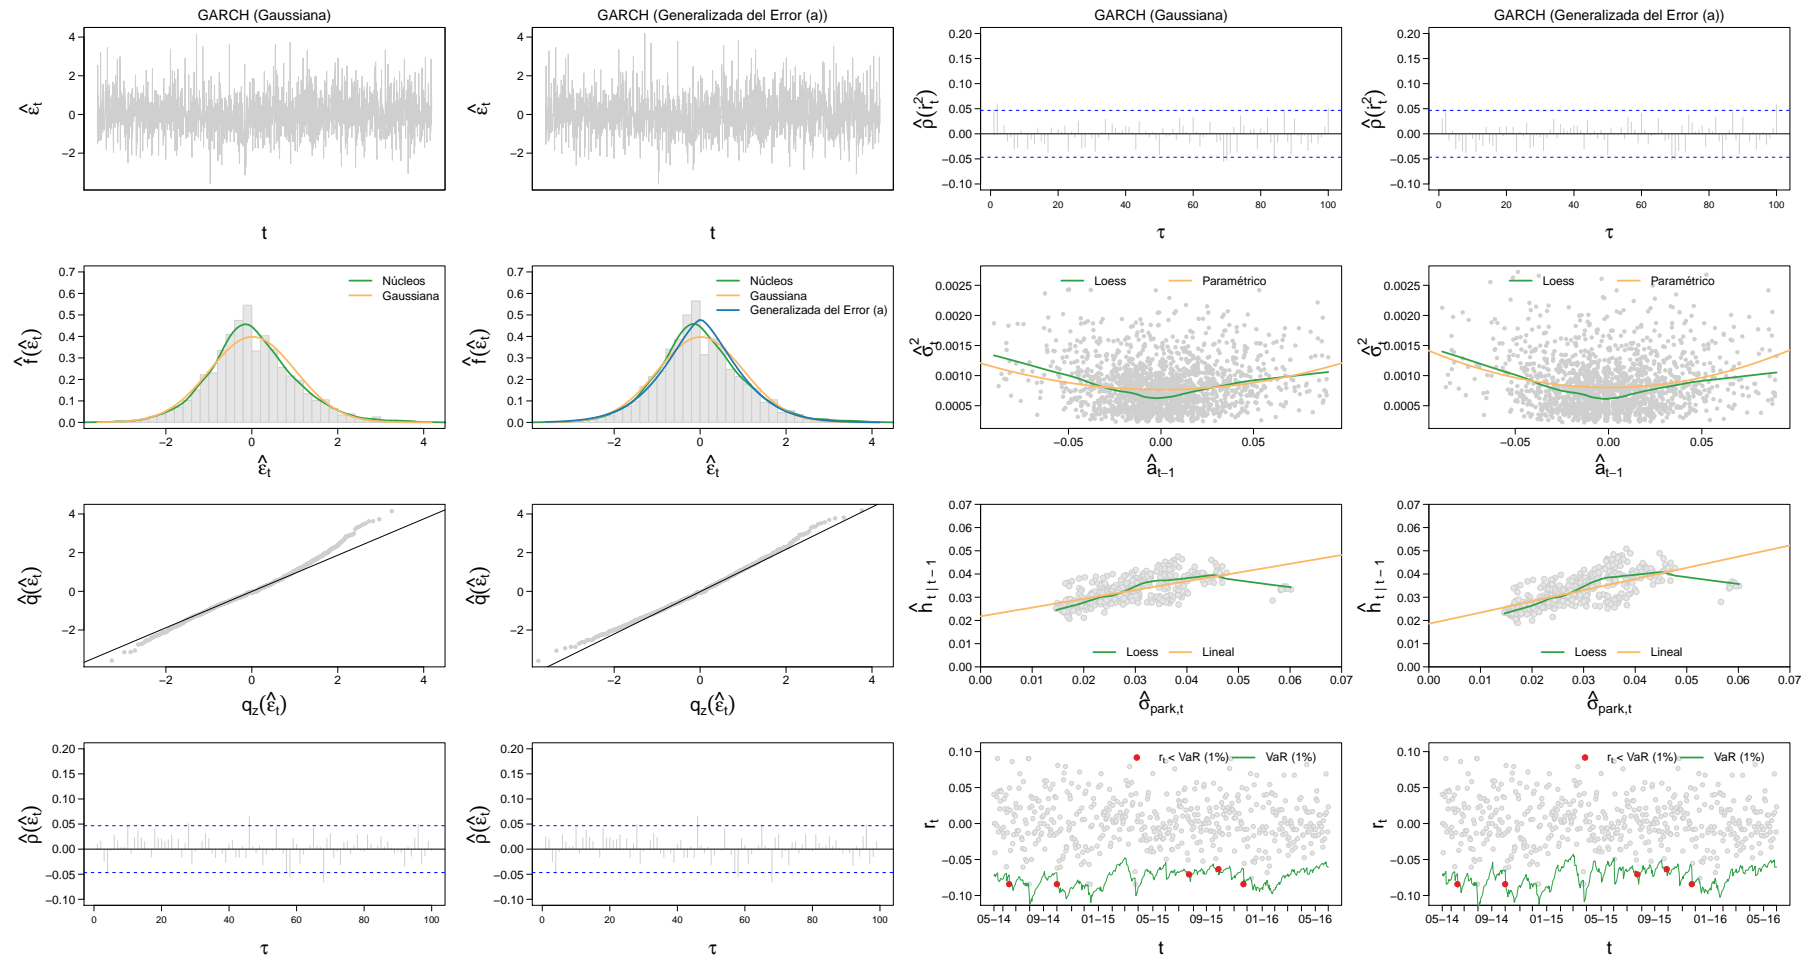
	Modelo base	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10
Especificación	GARCH	GARCH	eGARCH	GJRGARCH	NGARCH	TGARCH	GARCH	GJRGARCH	NGARCH	TGARCH	eGARCH
Densidad	norm	ged	ged	ged	ged	ged	sGED	sGED	sGED	sGED	sGED
<b>Panel A: Diagnóstico de residuos</b>											
Mínimo	-4.3120	-4.4230	-4.2500	-4.1150	-4.3540	-4.2550	-4.4370	-4.1210	-4.3720	-4.2550	-4.1780
Máximo	3.4630	3.4840	3.3850	3.3250	3.6200	3.6030	3.5100	3.3410	3.6380	3.6420	3.1480
Media	-0.0082	-0.0073	-0.0006	0.0016	-0.0108	-0.0012	0.0023	0.0099	0.0024	0.0067	0.0112
Mediana	-0.0138	-0.0070	-0.0069	-0.0026	-0.0110	-0.0043	0.0003	0.0079	0.0010	0.0028	0.0097
Desvío Estándar	1.0020	1.0020	1.0020	1.0020	1.0050	1.0020	1.0030	1.0020	1.0050	1.0030	1.0020
Asimetría	-0.2176	-0.2372	-0.2308	-0.2156	-0.2286	-0.2142	-0.2409	-0.2175	-0.2337	-0.2153	-0.2239
Curtosis	3.9270	3.9710	4.0170	3.9640	3.9420	4.0550	3.9780	3.9630	3.9500	4.0590	3.9930
$\chi^2$ Pearson (50)	85.5100	29.0300	46.9900	46.4200	30.6800	40.0600	36.3100	45.1700	42.0500	34.4900	46.4200
p-valor	0.0010	0.9896	0.5550	0.5783	0.9812	0.8150	0.9106	0.6291	0.7488	0.9421	0.5783
AIC	-5.0630	-5.0970	<u>-5.0990</u>	<u>-5.0990</u>	-5.0980	-5.0970	-5.0960	-5.0980	-5.0970	-5.0960	-5.0950
BIC	-5.0440	<u>-5.0750</u>	-5.0740	-5.0740	-5.0730	-5.0720	-5.0720	-5.0700	-5.0690	-5.0680	-5.0670
Jarque-Bera	76.8900	85.7000	91.4700	81.7900	80.3800	95.0300	87.1500	81.8300	82.2000	95.8200	87.0600
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	13.7300	15.6800	19.0700	16.2000	15.1200	18.9600	16.1300	16.1300	15.9000	19.0000	16.6600
p-valor	0.1856	0.1091	0.0394	0.0940	0.1279	0.0407	0.0960	0.0960	0.1026	0.0402	0.0822
$z^2$ Ljung-Box (10)	13.6240	15.5900	6.9520	8.6360	14.2050	7.6140	15.6100	8.9550	14.1280	7.8060	8.1730
p-valor	0.1909	0.1120	0.7300	0.5669	0.1639	0.6665	0.1113	0.5364	0.1672	0.6478	0.6119
Ljung-Box (22)	32.9400	34.3500	37.3300	35.6900	33.3200	37.9400	34.7600	35.5800	34.1200	37.8700	37.2900
p-valor	0.0627	0.0453	0.0217	0.0328	0.0576	0.0186	0.0411	0.0337	0.0478	0.0189	0.0220
$z^2$ Ljung-Box (22)	27.2300	28.7700	22.1900	22.7300	26.5900	25.5100	28.7400	22.7500	26.6100	25.3000	22.4600
p-valor	0.2027	0.1517	0.4485	0.4171	0.2271	0.2732	0.1526	0.4162	0.2264	0.2830	0.4330
Sesgo del signo	1.1358	0.6873	1.2416	1.0824	0.8087	0.9026	0.8415	1.1689	0.8442	1.0628	0.9617
p-valor	0.2562	0.4920	0.2146	0.2792	0.4188	0.3669	0.4002	0.2426	0.3987	0.2880	0.3363
Sesgo de tamaño negativo	1.2683	1.6529	0.1973	0.2902	1.5460	0.1211	1.5745	0.2726	1.5160	0.1875	0.1717
p-valor	0.2049	0.0985	0.8436	0.7717	0.1223	0.9036	0.1155	0.7852	0.1297	0.8513	0.8637
Sesgo de tamaño positivo	0.6533	0.8477	0.5426	0.7101	0.6562	0.6691	0.7895	0.6975	0.6987	0.5979	0.8638
p-valor	0.5136	0.3967	0.5875	0.4777	0.5118	0.5035	0.4299	0.4856	0.4848	0.5500	0.3878
Efecto conjunto	12.1320	12.1220	4.9260	6.4000	11.1780	3.6990	12.5090	6.8590	11.5130	4.1020	5.8760
p-valor	0.0069	0.0070	0.1773	0.0937	0.0108	0.2959	0.0058	0.0765	0.0093	0.2507	0.1178
<b>Panel B: Evaluación de pronósticos</b>											
Hit <sup>-</sup>	0.1367	0.1445	0.2070	0.1523	0.1367	0.2031	0.1445	0.1562	0.1328	0.2031	0.2031
Hit <sup>+</sup>	0.9012	0.9053	0.8683	0.8930	0.9136	0.8642	0.9053	0.8930	0.9136	0.8683	0.8683
MCPDC	0.5090	0.5150	0.5291	0.5130	0.5150	0.5251	0.5150	0.5150	0.5130	0.5271	0.5271
QLIKE	-2.9820	-2.9800	-2.9810	-2.9820	-2.9820	-2.9810	-2.9800	-2.9820	-2.9820	-2.9810	-2.9810
R <sup>2</sup>	0.7300	0.7194	0.6405	0.7108	0.7199	0.6291	0.7190	0.7113	0.7187	0.6290	0.6497
RMSE	0.0049	0.0051	0.0050	0.0049	0.0049	0.0051	0.0051	0.0049	0.0049	0.0051	0.0050
VaR excesos esperados	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000
VaR excesos observados	14.0000	11.0000	11.0000	12.0000	11.0000	11.0000	10.0000	11.0000	10.0000	10.0000	10.0000
VaR coeficiente de excesos	2.8000	2.2000	2.2000	2.4000	2.2000	2.2000	2.0000	2.2000	2.0000	2.0000	2.0000

**Cuadro B.8:** Estadísticos resumen de los residuos y los pronósticos correspondientes a distintos modelos aplicados a Merval (retornos truncados al 1%). Las densidades (s)norm, (s)std y (s)ged corresponden a las distribuciones gaussiana, t de Student y generalizada del error respectivamente, donde s hace referencia a la parametrización asimétrica. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (PAMP)



**Figura B.9:** Diagnóstico de residuos y evaluación de pronósticos para PAMP (retornos truncados al 1%).  
**Columnas I y III** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución gaussiana. **Columnas II y IV** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución generalizada del error asimétrica. **Columnas I y II** Primero: Serie de residuos estandarizados. Segundo: Histograma de los residuos estandarizados. Tercero: Gráfico de cuantil-cuantil de los residuos para la distribución supuesta por cada modelo. Cuarto: Autocorrelograma para los residuos. **Columnas III y IV** Primero: Autocorrelograma para el cuadrado de los residuos. Segundo: Curva de impacto de noticias. Tercero: Gráfico de dispersión de la volatilidad predicha un paso hacia adelante y la volatilidad histórica estimada según Parkinson. Cuarto: Gráfico de retornos observados y *Value At Risk* al 1% predicho en el momento anterior. En rojo, aquellos retornos que exceden el límite estimado. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (PAMP)

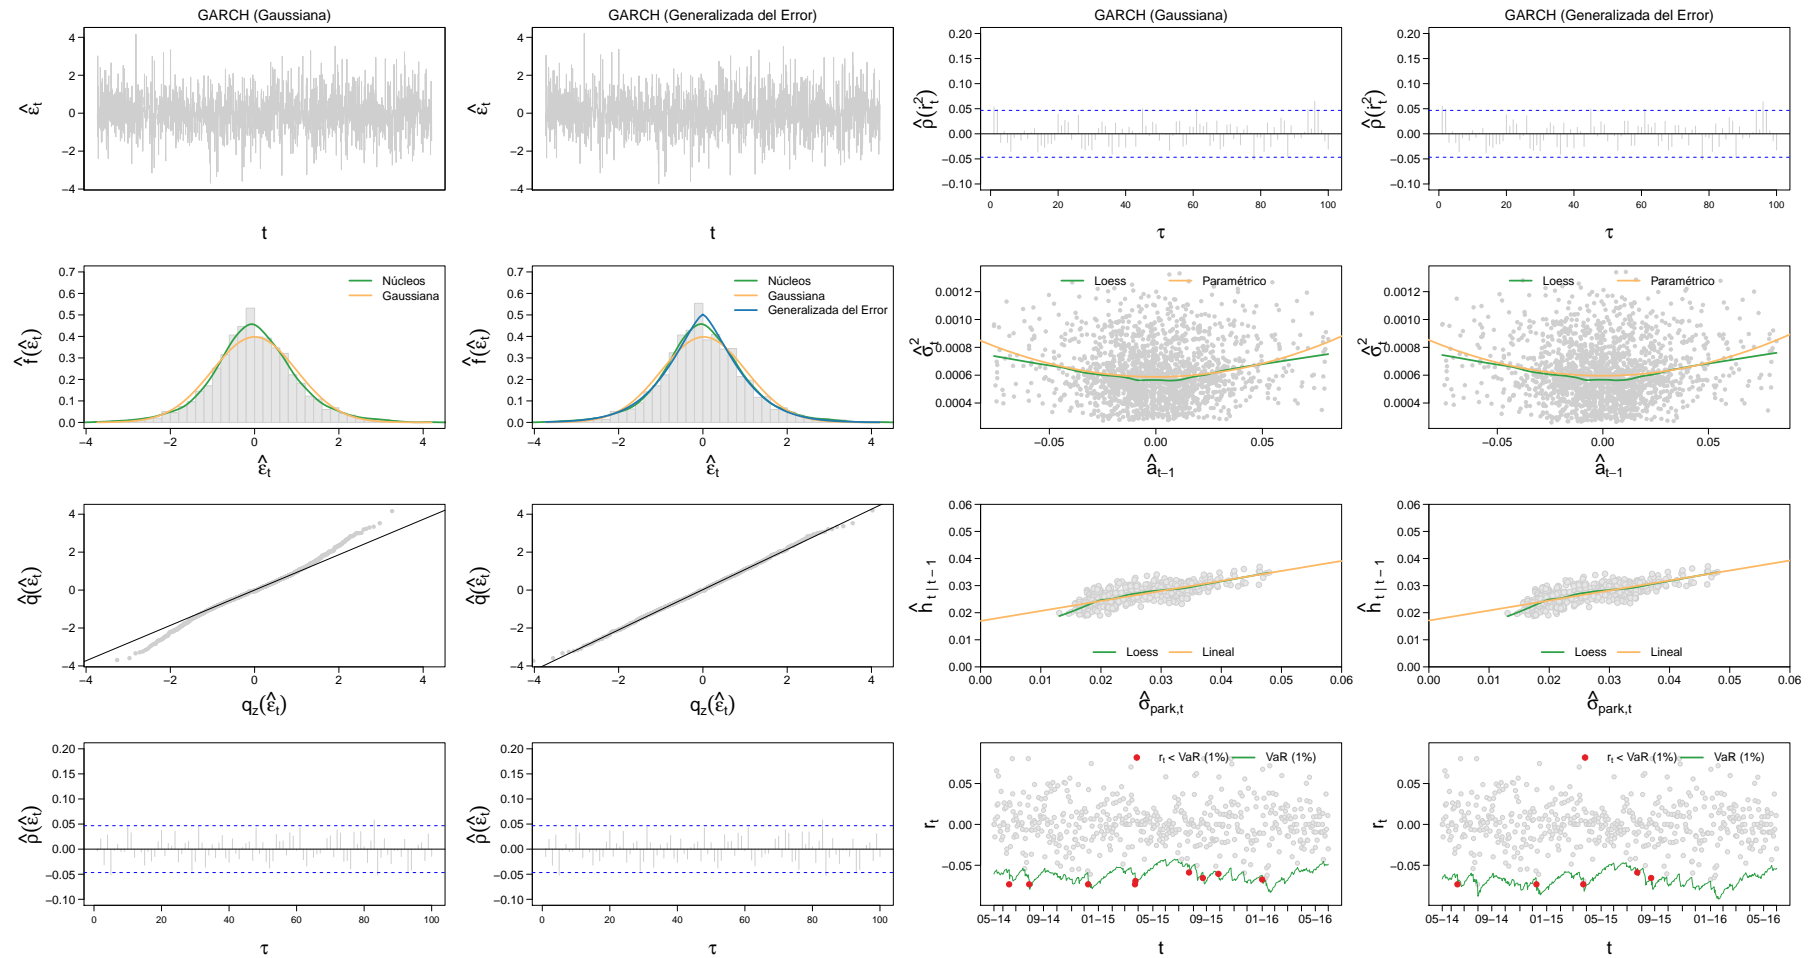
	Modelo base	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10
Especificación	GARCH	GARCH	eGARCH	TGARCH	NGARCH	GARCH	eGARCH	GJRGARCH	TGARCH	NGARCH	GJRGARCH
Densidad	norm	sged	sged	sged	sged	sstd	sstd	sged	sstd	sstd	sstd
<b>Panel A: Diagnóstico de residuos</b>											
Mínimo	-3.5790	-3.5940	-3.5500	-3.5220	-3.5540	-3.6370	-3.5960	-3.6010	-3.5700	-3.6030	-3.6460
Máximo	4.1450	4.1850	4.1540	4.1690	4.1090	4.2320	4.1950	4.2160	4.2170	4.1580	4.2620
Media	0.0147	0.0116	0.0068	0.0064	0.0119	0.0123	0.0051	0.0090	0.0054	0.0127	0.0096
Mediana	-0.0402	-0.0483	-0.0535	-0.0545	-0.0491	-0.0459	-0.0545	-0.0502	-0.0547	-0.0470	-0.0484
Desvío Estándar	1.0020	1.0040	1.0030	1.0050	1.0050	1.0010	1.0000	1.0030	1.0020	1.0020	1.0010
Asimetría	0.3209	0.3571	0.3529	0.3659	0.3670	0.3604	0.3540	0.3517	0.3658	0.3688	0.3545
Curtosis	3.7930	3.8570	3.8020	3.8460	3.8490	3.8880	3.8300	3.8480	3.8760	3.8800	3.8790
$\chi^2$ Pearson (50)	172.4000	199.8000	255.4000	263.6000	239.6000	169.2000	210.2000	205.8000	206.4000	182.8000	163.5000
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
AIC	-4.4080	-4.4390	<u>-4.4420</u>	-4.4400	-4.4390	-4.4360	-4.4390	-4.4380	-4.4370	-4.4360	-4.4350
BIC	-4.3890	<u>-4.4140</u>	-4.4140	-4.4120	-4.4110	-4.4110	-4.4110	-4.4100	-4.4090	-4.4080	-4.4070
Jarque-Bera	76.4000	91.3100	83.6900	91.8300	92.4200	95.9700	87.3700	89.1100	95.5200	96.7400	93.5600
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	11.0000	12.0400	12.8300	12.6000	12.3400	11.5400	12.6300	12.3100	12.3900	11.7600	11.8400
p-valor	0.3579	0.2822	0.2335	0.2466	0.2632	0.3174	0.2450	0.2649	0.2599	0.3017	0.2959
$z^2$ Ljung-Box (10)	14.1000	12.1700	14.1800	15.4600	13.7600	12.1300	14.2700	12.5800	15.4700	13.7000	12.4900
p-valor	0.1684	0.2739	0.1651	0.1163	0.1840	0.2762	0.1609	0.2484	0.1157	0.1873	0.2537
Ljung-Box (22)	21.9300	23.7400	25.1500	25.0400	24.3100	23.1800	25.0600	24.0600	24.9400	23.6800	23.5500
p-valor	0.4643	0.3608	0.2901	0.2950	0.3313	0.3915	0.2940	0.3439	0.3001	0.3642	0.3714
$z^2$ Ljung-Box (22)	21.2000	20.8800	23.5300	23.3300	22.1800	21.1800	24.0400	21.3400	23.5900	22.4200	21.6000
p-valor	0.5087	0.5280	0.3722	0.3832	0.4489	0.5098	0.3453	0.4999	0.3689	0.4350	0.4841
Sesgo del signo	0.0656	0.0371	0.3050	0.3653	0.1926	0.1172	0.3179	0.0454	0.4093	0.1911	0.0210
p-valor	0.9477	0.9704	0.7604	0.7149	0.8473	0.9067	0.7506	0.9638	0.6824	0.8484	0.9832
Sesgo de tamaño negativo	1.2800	0.6168	0.6288	0.6234	0.3754	0.4131	0.4979	0.8355	0.5017	0.2348	0.6396
p-valor	0.2007	0.5375	0.5296	0.5331	0.7074	0.6796	0.6186	0.4036	0.6159	0.8144	0.5225
Sesgo de tamaño positivo	2.0010	1.3880	1.3410	1.3090	1.3180	1.2590	1.2050	1.3200	1.2040	1.1570	1.1920
p-valor	0.0456	0.1653	0.1801	0.1909	0.1877	0.2083	0.2284	0.1870	0.2288	0.2474	0.2333
Efecto conjunto	6.3860	2.8150	2.2630	2.1250	2.2280	2.1350	1.7410	2.8200	1.7060	1.7080	2.1190
p-valor	0.0942	0.4210	0.5197	0.5469	0.5264	0.5449	0.6279	0.4203	0.6356	0.6351	0.5481
<b>Panel B: Evaluación de pronósticos</b>											
Hit <sup>-</sup>	0.1903	0.1791	0.1866	0.1866	0.1903	0.1716	0.1791	0.1716	0.1754	0.1754	0.1679
Hit <sup>+</sup>	0.8000	0.8304	0.8174	0.8217	0.8130	0.8478	0.8261	0.8261	0.8304	0.8435	0.8304
MCPDC	0.4709	0.4790	0.4770	0.4790	0.4770	0.4830	0.4770	0.4729	0.4770	0.4830	0.4729
QLIKE	-2.5610	-2.5650	-2.5620	-2.5620	-2.5640	-2.5640	-2.5600	-2.5640	-2.5590	-2.5620	-2.5630
R <sup>2</sup>	0.3884	0.4541	0.3875	0.3794	0.4193	0.4503	0.3789	0.4344	0.3696	0.4145	0.4288
RMSE	0.0078	0.0074	0.0077	0.0079	0.0076	0.0076	0.0080	0.0075	0.0082	0.0079	0.0077
VaR excesos esperados	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000
VaR excesos observados	5.0000	5.0000	4.0000	4.0000	4.0000	5.0000	4.0000	5.0000	4.0000	4.0000	5.0000
VaR coeficiente de excesos	1.0000	1.0000	0.8000	0.8000	0.8000	1.0000	0.8000	1.0000	0.8000	0.8000	1.0000

**Cuadro B.9:** Estadísticos resumen de los residuos y los pronósticos correspondientes a distintos modelos aplicados a PAMP (retornos truncados al 1%). Las densidades (s)norm, (s)std y (s)ged corresponden a las distribuciones gaussiana, t de Student y generalizada del error respectivamente, donde s hace referencia a la parametrización asimétrica. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (TECO2)



**Figura B.10:** Diagnóstico de residuos y evaluación de pronósticos para TECO2 (retornos truncados al 1%).  
**Columnas I y III** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución gaussiana. **Columnas II y IV** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución generalizada del error. **Columnas I y II** Primer: Serie de residuos estandarizados. Segundo: Histograma de los residuos estandarizados. Tercero: Gráfico de cuantil-cuantil de los residuos para la distribución supuesta por cada modelo. Cuarto: Autocorrelograma para los residuos. **Columnas III y IV** Primer: Autocorrelograma para el cuadrado de los residuos. Segundo: Curva de impacto de noticias. Tercero: Gráfico de dispersión de la volatilidad predicha un paso hacia adelante y la volatilidad histórica estimada según Parkinson. Cuarto: Gráfico de retornos observados y *Value At Risk* al 1% predicho en el momento anterior. En rojo, aquellos retornos que exceden el límite estimado. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (TECO2)

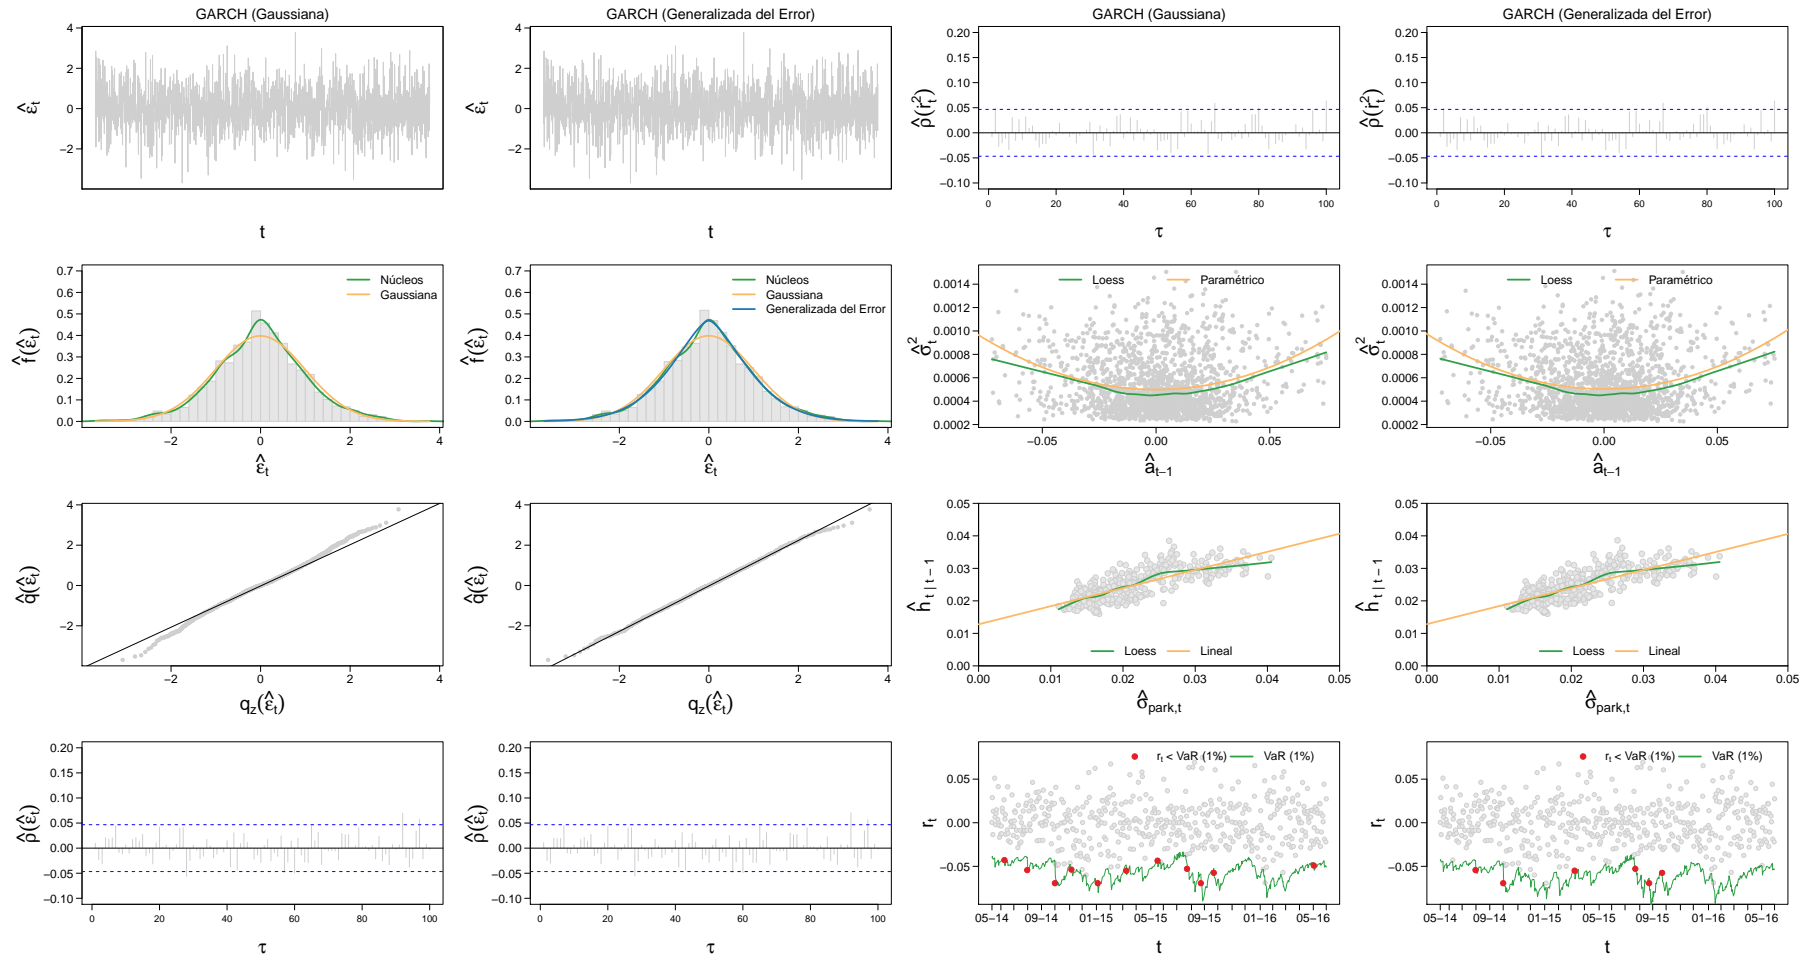
	Modelo base	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10
Especificación	GARCH	GARCH	eGARCH	GARCH	GJRGARCH	NGARCH	eGARCH	TGARCH	GJRGARCH	TGARCH	NGARCH
Densidad	norm	ged	ged	sged	ged	ged	sged	ged	sged	sged	sged
<b>Panel A: Diagnóstico de residuos</b>											
Mínimo	-3.6880	-3.7320	-3.3730	-3.7040	-3.5330	-3.8190	-3.3620	-3.2990	-3.4980	-3.3050	-3.8210
Máximo	4.1640	4.2020	4.3360	4.1810	4.1840	4.1570	4.3270	4.3400	4.1660	4.3210	4.1360
Media	-0.0023	0.0193	0.0224	0.0011	0.0218	0.0193	0.0029	0.0233	0.0041	0.0022	0.0022
Mediana	-0.0453	-0.0199	-0.0185	-0.0395	-0.0175	-0.0197	-0.0389	-0.0188	-0.0363	-0.0403	-0.0370
Desvío Estándar	1.0030	1.0030	1.0020	1.0030	1.0030	1.0020	1.0030	1.0040	1.0030	1.0040	1.0020
Asimetría	0.0835	0.0810	0.1243	0.0839	0.0853	0.0649	0.1292	0.1499	0.0902	0.1521	0.0645
Curtosis	3.9280	3.9420	3.9170	3.9350	3.8940	3.9360	3.9190	3.9880	3.8910	3.9870	3.9300
$\chi^2$ Pearson (50)	135.5100	91.7600	108.3000	91.5300	90.1700	96.6500	90.4500	105.9700	83.0100	91.6500	98.3000
p-valor	<0.0001	0.0002	<0.0001	0.0002	0.0003	<0.0001	0.0003	<0.0001	0.0017	0.0002	<0.0001
AIC	-4.5960	-4.6270	-4.6280	-4.6270	-4.6270	-4.6260	-4.6290	-4.6250	-4.6270	-4.6260	-4.6260
BIC	-4.5770	-4.6050	-4.6030	-4.6020	-4.6020	-4.6010	-4.6010	-4.6000	-4.5990	-4.5980	-4.5980
Jarque-Bera	65.2500	67.0100	66.1900	66.1600	60.6800	65.4500	66.8300	78.1200	60.6200	78.1600	64.6800
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	12.5700	12.9400	11.8600	12.7700	12.4100	13.2300	11.8700	12.1300	12.3200	12.1300	13.0200
p-valor	0.2489	0.2268	0.2946	0.2368	0.2588	0.2111	0.2939	0.2761	0.2640	0.2762	0.2227
$z^2$ Ljung-Box (10)	13.0790	13.5600	10.0800	13.0980	10.9120	15.0910	9.7440	8.9430	10.3970	8.7710	15.1490
p-valor	0.2193	0.1940	0.4335	0.2182	0.3644	0.1288	0.4632	0.5375	0.4064	0.5539	0.1267
Ljung-Box (22)	21.6500	21.9800	20.5800	21.7700	21.2100	22.4000	20.6000	21.0300	21.0800	21.0500	22.2100
p-valor	0.4809	0.4614	0.5468	0.4738	0.5079	0.4363	0.5458	0.5187	0.5157	0.5175	0.4475
$z^2$ Ljung-Box (22)	24.0800	24.8700	22.1800	24.1500	22.3700	26.4700	21.5800	20.7600	21.5700	20.2900	26.2500
p-valor	0.3430	0.3033	0.4491	0.3393	0.4378	0.2322	0.4853	0.5355	0.4859	0.5651	0.2411
Sesgo del signo	2.2970	2.1140	1.9790	2.1530	2.1130	2.2020	2.0350	1.8240	1.9770	1.9010	2.2650
p-valor	0.0217	0.0346	0.0479	0.0314	0.0347	0.0278	0.0420	0.0683	0.0482	0.0574	0.0236
Sesgo de tamaño negativo	3.6310	3.6060	2.6310	3.5250	3.1370	3.7790	2.5430	2.4000	2.9560	2.3500	3.7550
p-valor	0.0003	0.0003	0.0086	0.0004	0.0017	0.0002	0.0111	0.0165	0.0032	0.0189	0.0002
Sesgo de tamaño positivo	0.5380	0.4346	0.5310	0.4883	0.4263	0.3676	0.6182	0.5653	0.4025	0.6502	0.3986
p-valor	0.5906	0.6639	0.5955	0.6254	0.6699	0.7132	0.5365	0.5720	0.6874	0.5157	0.6902
Efecto conjunto	13.5290	13.2010	7.5000	12.6910	10.2090	14.4330	7.2320	6.2880	9.0540	6.2320	14.3060
p-valor	0.0036	0.0042	0.0576	0.0054	0.0169	0.0024	0.0649	0.0984	0.0286	0.1009	0.0025
<b>Panel B: Evaluación de pronósticos</b>											
Hit <sup>-</sup>	0.4618	0.4538	0.4659	0.4498	0.4378	0.4578	0.4819	0.5020	0.4337	0.5141	0.4578
Hit <sup>+</sup>	0.6080	0.6120	0.5920	0.6120	0.6160	0.5960	0.5960	0.5800	0.6160	0.5720	0.6000
MCPDC	0.5351	0.5331	0.5291	0.5311	0.5271	0.5271	0.5391	0.5411	0.5251	0.5431	0.5291
QLIKE	-2.6450	-2.6450	-2.6490	-2.6450	-2.6450	-2.6420	-2.6490	-2.6500	-2.6450	-2.6500	-2.6430
$R^2$	0.5655	0.5535	0.6583	0.5643	0.5414	0.4863	0.6699	0.6744	0.5552	0.6770	0.4912
RMSE	0.0051	0.0051	0.0045	0.0051	0.0051	0.0054	0.0045	0.0044	0.0050	0.0044	0.0054
VaR excesos esperados	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000
VaR excesos observados	9.0000	5.0000	4.0000	7.0000	4.0000	5.0000	7.0000	4.0000	6.0000	8.0000	7.0000
VaR coeficiente de excesos	1.8000	1.0000	0.8000	1.4000	0.8000	1.0000	1.4000	0.8000	1.2000	1.6000	1.4000

**Cuadro B.10:** Estadísticos resumen de los residuos y los pronósticos correspondientes a distintos modelos aplicados a TECO2 (retornos truncados al 1%). Las densidades (s)norm, (s)std y (s)ged corresponden a las distribuciones gaussiana, t de Student y generalizada del error respectivamente, donde s hace referencia a la parametrización asimétrica. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (TS)



**Figura B.11:** Diagnóstico de residuos y evaluación de pronósticos para TS (retornos truncados al 1%).  
**Columnas I y III** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución gaussiana. **Columnas II y IV** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución generalizada del error. **Columnas I y II** Primero: Serie de residuos estandarizados. Segundo: Histograma de los residuos estandarizados. Tercero: Gráfico de cuantil-cuantil de los residuos para la distribución supuesta por cada modelo. Cuarto: Autocorrelograma para los residuos. **Columnas III y IV** Primero: Autocorrelograma para el cuadrado de los residuos. Segundo: Curva de impacto de noticias. Tercero: Gráfico de dispersión de la volatilidad predicha un paso hacia adelante y la volatilidad histórica estimada según Parkinson. Cuarto: Gráfico de retornos observados y *Value At Risk* al 1% predicho en el momento anterior. En rojo, aquellos retornos que exceden el límite estimado. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (TS)

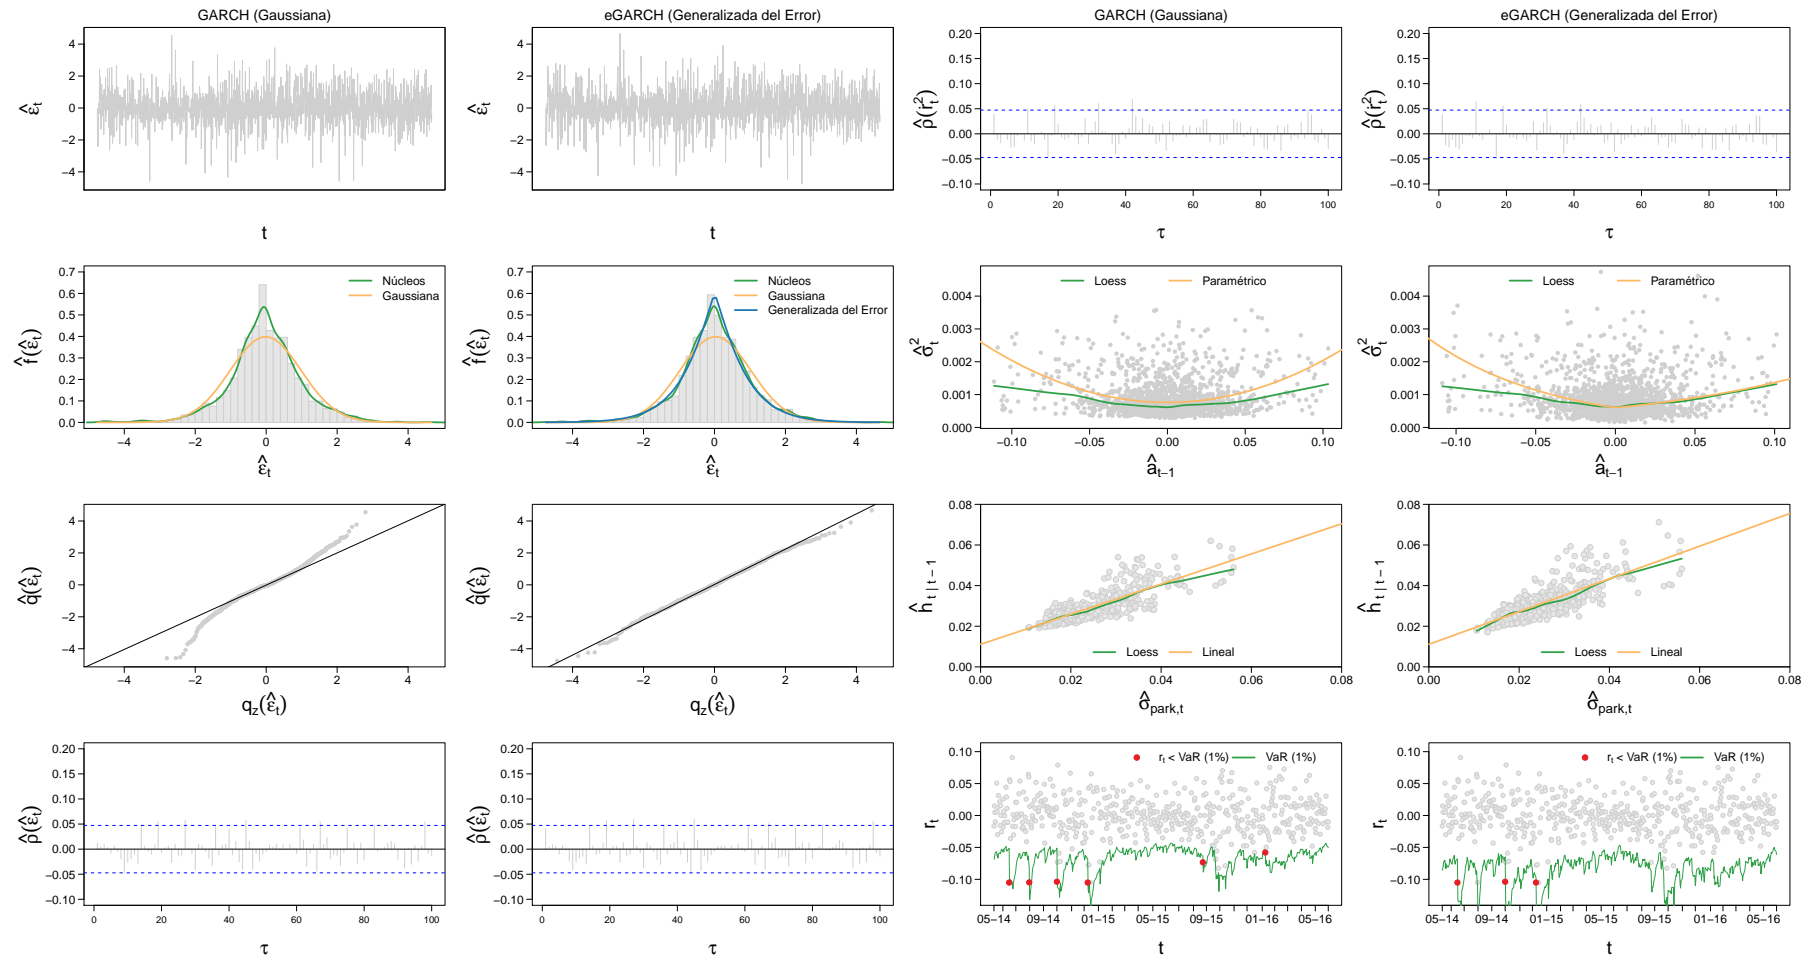
	Modelo base	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10
Especificación	GARCH	GARCH	eGARCH	GJRGARCH	NGARCH	GARCH	TGARCH	eGARCH	GJRGARCH	NGARCH	TGARCH
Densidad	norm	ged	ged	ged	ged	sged	ged	sged	sged	sged	sged
<b>Panel A: Diagnóstico de residuos</b>											
Mínimo	-3.6900	-3.6890	-3.6110	-3.6720	-3.6480	-3.6510	-3.5750	-3.6100	-3.6710	-3.6470	-3.5750
Máximo	3.7770	3.7770	3.4340	3.7150	3.7140	3.7910	3.6180	3.4360	3.7190	3.7180	3.6180
Media	-0.0055	-0.0045	-0.0058	0.0002	-0.0049	-0.0024	-0.0063	-0.0051	0.0018	-0.0039	-0.0063
Mediana	-0.0072	-0.0088	-0.0139	-0.0089	-0.0139	-0.0118	-0.0143	-0.0132	-0.0075	-0.0132	-0.0143
Desvío Estándar	1.0030	1.0010	1.0020	1.0020	1.0020	1.0020	1.0040	1.0020	1.0020	1.0020	1.0040
Asimetría	-0.0303	-0.0298	-0.0378	-0.0428	-0.0378	-0.0420	-0.0187	-0.0378	-0.0428	-0.0378	-0.0187
Curtosis	3.5130	3.5140	3.5030	3.5150	3.5180	3.5150	3.5590	3.5030	3.5150	3.5180	3.5590
$\chi^2$ Pearson (50)	79.2900	42.2100	79.9700	75.2000	73.2700	73.4400	74.9700	77.1900	74.2400	80.7100	74.7500
p-valor	0.0040	0.7429	0.0034	0.0094	0.0139	0.0135	0.0099	0.0062	0.0115	0.0029	0.0104
AIC	-4.7710	<u>-4.7860</u>	-4.7830	-4.7810	-4.7810	-4.7810	-4.7800	-4.7820	-4.7800	-4.7800	-4.7790
BIC	-4.7530	<u>-4.7640</u>	-4.7580	-4.7570	-4.7560	-4.7560	-4.7560	-4.7540	-4.7540	-4.7520	-4.7510
Jarque-Bera	19.6000	19.6700	18.9900	19.9900	20.1000	19.9900	23.0700	18.9900	19.9800	20.0900	23.0700
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	8.7960	8.8650	11.9620	11.9710	11.7930	11.6190	12.4670	11.9670	11.9740	11.7930	12.4660
p-valor	0.5516	0.5449	0.2876	0.2870	0.2991	0.3114	0.2550	0.2873	0.2868	0.2991	0.2551
$z^2$ Ljung-Box (10)	12.2900	12.3100	11.7600	10.5200	10.9800	10.8000	10.7600	11.7700	10.5400	11.0000	10.7600
p-valor	0.2662	0.2651	0.3018	0.3964	0.3587	0.3734	0.3765	0.3008	0.3941	0.3575	0.3766
Ljung-Box (22)	17.7700	17.8500	23.8000	23.3600	23.4200	23.0600	24.4200	23.8100	23.3600	23.4100	24.4200
p-valor	0.7194	0.7151	0.3576	0.3819	0.3786	0.3984	0.3255	0.3572	0.3817	0.3787	0.3255
$z^2$ Ljung-Box (22)	18.9100	18.9500	18.6000	17.1400	17.8000	17.6700	17.5600	18.6300	17.1900	17.8300	17.5500
p-valor	0.6509	0.6483	0.6700	0.7555	0.7178	0.7254	0.7319	0.6683	0.7529	0.7157	0.7320
Sesgo del signo	1.2680	1.4760	1.6810	1.5410	1.7060	1.6450	1.7920	1.6810	1.6010	1.7030	1.7920
p-valor	0.2051	0.1402	0.0930	0.1236	0.0882	0.1001	0.0733	0.0929	0.1095	0.0887	0.0733
Sesgo de tamaño negativo	0.9279	1.0443	1.5186	1.2587	1.2603	1.1344	1.7011	1.5191	1.2958	1.2575	1.7010
p-valor	0.3536	0.2965	0.1290	0.2083	0.2077	0.2568	0.0891	0.1289	0.1952	0.2087	0.0891
Sesgo de tamaño positivo	0.3028	0.2052	0.1440	0.1216	0.0599	0.0179	0.1207	0.1448	0.1482	0.0619	0.1207
p-valor	0.7621	0.8374	0.8855	0.9032	0.9522	0.9857	0.9039	0.8849	0.8822	0.9507	0.9039
Efecto conjunto	2.9830	3.5840	3.8330	3.1340	4.2800	3.8940	4.5240	3.8360	3.3330	4.2790	4.5230
p-valor	0.3942	0.3100	0.2801	0.3715	0.2327	0.2731	0.2102	0.2797	0.3431	0.2329	0.2102
<b>Panel B: Evaluación de pronósticos</b>											
Hit <sup>-</sup>	0.2151	0.2231	0.1952	0.2231	0.2112	0.2191	0.1952	0.1952	0.2231	0.2151	0.1873
Hit <sup>+</sup>	0.8508	0.8468	0.8790	0.8589	0.8669	0.8468	0.8831	0.8831	0.8548	0.8629	0.8831
MCPDC	0.5311	0.5331	0.5351	0.5391	0.5371	0.5311	0.5371	0.5371	0.5371	0.5371	0.5331
QLIKE	-2.8850	-2.8850	-2.8820	-2.8850	-2.8840	-2.8850	-2.8820	-2.8820	-2.8850	-2.8840	-2.8820
$R^2$	0.6183	0.6179	0.6175	0.6217	0.6173	0.6207	0.6223	0.6180	0.6208	0.6147	0.6220
RMSE	0.0053	0.0053	0.0056	0.0053	0.0054	0.0053	0.0056	0.0056	0.0053	0.0054	0.0056
VaR excesos esperados	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000
VaR excesos observados	11.0000	6.0000	5.0000	6.0000	6.0000	6.0000	6.0000	5.0000	6.0000	6.0000	6.0000
VaR coeficiente de excesos	2.2000	1.2000	1.0000	1.2000	1.2000	1.2000	1.2000	1.0000	1.2000	1.2000	1.2000

**Cuadro B.11:** Estadísticos resumen de los residuos y los pronósticos correspondientes a distintos modelos aplicados a TS (retornos truncados al 1 %). Las densidades (s)norm, (s)std y (s)ged corresponden a las distribuciones gaussianas, t de Student y generalizada del error respectivamente, donde s hace referencia a la parametrización asimétrica. Elaboración propia.

# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (YPFD)



**Figura B.12:** Diagnóstico de residuos y evaluación de pronósticos para YPFD (retornos truncados al 1%).

**Columnas I y III** Modelo  $ARMA(1, 1) - GARCH(1, 1)$  con distribución gaussiana. **Columnas II y IV** Modelo  $ARMA(1, 1) - eGARCH(1, 1)$  con distribución generalizada del error. **Columnas I y II** Primer: Serie de residuos estandarizados. Segundo: Histograma de los residuos estandarizados. Tercero: Gráfico de cuantil-cuantil de los residuos para la distribución supuesta por cada modelo. Cuarto: Autocorrelograma para los residuos. **Columnas III y IV** Primer: Autocorrelograma para el cuadrado de los residuos. Segundo: Curva de impacto de noticias. Tercero: Gráfico de dispersión de la volatilidad predicha un paso hacia adelante y la volatilidad histórica estimada según Parkinson. Cuarto: Gráfico de retornos observados y *Value At Risk* al 1% predicho en el momento anterior. En rojo, aquellos retornos que exceden el límite estimado. Elaboración propia.



# ANEXO B

## Modelos de heterocedasticidad condicional

### Diagnóstico y evaluación de pronósticos (YFPD)

	Modelo base	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8	Modelo 9	Modelo 10
Especificación	GARCH	eGARCH	TGARCH	eGARCH	GJRGARCH	GARCH	TGARCH	NGARCH	GJRGARCH	GARCH	NGARCH
Densidad	norm	ged	ged	sged	ged	ged	sged	ged	sged	sged	sged
<b>Panel A: Diagnóstico de residuos</b>											
Mínimo	-4.5890	-4.7580	-4.8470	-4.7880	-4.8400	-4.7170	-4.8740	-4.5830	-4.8700	-4.6750	-4.5340
Máximo	4.5490	4.6650	4.5470	4.6370	4.6410	4.7450	4.5260	4.7100	4.5940	4.6870	4.6720
Media	-0.0149	0.0267	0.0265	0.0109	0.0257	0.0183	0.0114	0.0187	0.0090	-0.0018	0.0005
Mediana	-0.0452	-0.0043	-0.0026	-0.0229	-0.0043	-0.0125	-0.0200	-0.0122	-0.0233	-0.0333	-0.0313
Desvío Estándar	1.0020	1.0010	1.0020	1.0010	1.0010	1.0010	1.0020	1.0020	1.0010	1.0000	1.0010
Asimetría	-0.1484	-0.1188	-0.1341	-0.1138	-0.1530	-0.1554	-0.1286	-0.1524	-0.1488	-0.1496	-0.1451
Curtosis	4.9750	4.9620	4.9900	4.9630	5.1280	5.0670	4.9950	4.9870	5.1260	5.0620	4.9860
$\chi^2$ Pearson (50)	164.7700	86.7100	103.3600	92.6500	97.4200	88.4000	90.2100	77.9300	97.7700	100.9800	87.3600
p-valor	<0.0001	0.0007	<0.0001	0.0002	<0.0001	0.0005	0.0003	0.0053	<0.0001	<0.0001	0.0006
AIC	-4.3720	<u>-4.4620</u>	-4.4600	-4.4610	-4.4570	-4.4530	-4.4590	-4.4550	-4.4570	-4.4530	-4.4550
BIC	-4.3530	<u>-4.4360</u>	-4.4340	-4.4330	-4.4320	-4.4310	-4.4310	-4.4290	-4.4280	-4.4270	-4.4260
Jarque-Bera	285.4000	279.6000	288.7000	279.6000	330.8000	312.6000	289.7000	289.2000	329.8000	310.7000	288.3000
p-valor	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001	<0.0001
Ljung-Box (10)	6.2520	8.5370	8.6950	8.6730	8.3330	8.7450	9.0460	9.3670	8.4650	8.8040	9.5110
p-valor	0.7936	0.5765	0.5612	0.5634	0.5964	0.5565	0.5278	0.4977	0.5835	0.5508	0.4844
$z^2$ Ljung-Box (10)	6.3840	8.3530	9.1700	8.0830	6.7950	7.2730	8.8520	8.5560	6.7080	7.1220	8.2750
p-valor	0.7820	0.5944	0.5161	0.6208	0.7447	0.6994	0.5462	0.5747	0.7527	0.7139	0.6019
Ljung-Box (22)	18.2200	21.3800	21.8500	21.6100	19.8500	20.1800	22.3100	21.5500	20.0700	20.3100	21.8400
p-valor	0.6927	0.4975	0.4689	0.4833	0.5921	0.5720	0.4415	0.4868	0.5788	0.5635	0.4697
$z^2$ Ljung-Box (22)	22.0000	26.2000	27.4000	26.2100	24.3100	22.9300	27.4400	23.9100	24.4900	23.1300	24.0700
p-valor	0.4597	0.2431	0.1963	0.2426	0.3313	0.4055	0.1950	0.3518	0.3219	0.3943	0.3437
Sesgo del signo	0.4903	0.4340	0.3800	0.2854	0.4815	0.1498	0.4857	0.2556	0.4857	0.0754	0.3063
p-valor	0.6240	0.6643	0.7040	0.7754	0.6302	0.8809	0.7983	0.6273	0.8040	0.9399	0.7594
Sesgo de tamaño negativo	1.6576	0.3997	0.3942	0.4180	0.3786	1.5147	0.3979	1.2771	0.4408	1.4236	1.2427
p-valor	0.0976	0.6895	0.6935	0.6760	0.7050	0.1300	0.6907	0.2017	0.6594	0.1547	0.2142
Sesgo de tamaño positivo	0.4217	0.5508	0.5169	0.4227	0.6303	0.1680	0.3999	0.1725	0.4756	0.2314	0.2917
p-valor	0.6733	0.5818	0.6053	0.6726	0.5286	0.8666	0.6893	0.8630	0.6344	0.8171	0.7706
Efecto conjunto	5.0438	0.6807	0.5913	0.4775	0.7477	4.1626	0.4175	4.4866	0.4949	3.5869	3.8391
p-valor	0.1686	0.8777	0.8984	0.9238	0.8619	0.2444	0.9366	0.2135	0.9200	0.3097	0.2794
<b>Panel B: Evaluación de pronósticos</b>											
Hit <sup>-</sup>	0.1970	0.1818	0.1742	0.1932	0.1818	0.1591	0.1818	0.1553	0.1970	0.1780	0.1742
Hit <sup>+</sup>	0.9060	0.9487	0.9573	0.9487	0.9274	0.9103	0.9573	0.9359	0.9316	0.9145	0.9402
MCPDC	0.5291	0.5411	0.5411	0.5471	0.5311	0.5110	0.5451	0.5210	0.5411	0.5230	0.5331
QLIKE	-2.7260	-2.7160	-2.7140	-2.7170	-2.7230	-2.7220	-2.7150	-2.7170	-2.7230	-2.7230	-2.7180
$R^2$	0.6627	0.6289	0.6441	0.6251	0.6370	0.6451	0.6406	0.6532	0.6355	0.6468	0.6542
RMSE	0.0068	0.0083	0.0087	0.0081	0.0078	0.0075	0.0085	0.0081	0.0077	0.0074	0.0080
VaR excesos esperados	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000	5.0000
VaR excesos observados	6.0000	3.0000	3.0000	3.0000	3.0000	3.0000	3.0000	3.0000	4.0000	4.0000	3.0000
VaR coeficiente de excesos	1.2000	0.6000	0.6000	0.6000	0.6000	0.6000	0.6000	0.6000	0.8000	0.8000	0.6000

**Cuadro B.12:** Estadísticos resumen de los residuos y los pronósticos correspondientes a distintos modelos aplicados a YFPD (retornos truncados al 1%). Las densidades (s)norm, (s)std y (s)ged corresponden a las distribuciones gaussiana, t de Student y generalizada del error respectivamente, donde s hace referencia a la parametrización asimétrica. Elaboración propia.