



Universidad de San Andrés

Escuela de Administración y Negocios

Magister en Finanzas

Nombre del Trabajo Final de Graduación:

DETECTANDO FRAGMENTACIÓN EN EL MERCADO DE
BONOS SOBERANOS A TRAVÉS DE CORRELACIONES
DINÁMICAS

Autora: Farah Daniela Mugrabi

DNI: 33.443.964

Directora de Tesis: Prof. Paula Margaretic

Buenos Aires, Marzo de 2023

Agradecimientos: Quisiera agradecer a Prof. Paula Margaretic, Prof. Gabriel A. Basaluzzo y Prof. Elsa Cortina por su apoyo, confianza y aliento para que continúe mis estudios y emprenda un Doctorado en Economía. Brindo mi gratitud a la Universidad de San Andrés por brindarme una excelente educación en conjunción con la oportunidad de representar a la universidad en un programa de intercambio de estudios en el extranjero. A mi familia, amigos y colegas agradezco profundamente su apoyo incondicional.



Universidad de
San Andrés

Resumen

La fragmentación en el mercado de bonos soberanos en la Unión Monetaria Europea (UME) implica divergencias de curvas de tasas de interés entre sus países miembros. La causa de estas divergencias obedece a que los *shocks* puramente locales no pueden ser enteramente diversificados por restricciones de liquidez u otras fuentes de ineficiencia de mercado (Baele et al., 2004). De esta manera, los *shocks* globales presentan una relativa menor incidencia en los retornos de mercados fragmentados¹. Con el fin de capturar el grado fragmentación, la literatura precedente se ha basado en la estimación de la sensibilidad de la media de los retornos de un mercado ante factores globales, i.e. betas de mercado. Mientras que algunas metodologías propuestas permiten que los betas puedan variar a través de determinados sub-períodos, sigue siendo necesario indagar en nuevos indicadores que permitan que la sensibilidad a factores comunes sea dinámica (Costola & Iacopini, 2023²). Proponemos identificar fragmentación a través de las correlaciones dinámicas entre los retornos de bonos soberanos de tres países miembros de la UME, i.e. Francia, Italia y Grecia, y un mercado representante de factores puramente globales. Utilizando el modelo DCC-GARCH estimamos el grado de sincronización de tasas de interés entre ambos mercados variante en el tiempo luego de excluir la incidencia de *shocks* idiosincráticos. Aplicamos el algoritmo de Oka & Perron (2018) para identificar múltiples quiebres estructurales que puedan tomar lugar en períodos desconocidos.

¹Los retornos están determinado por dos fuentes de riesgo, i.e. el riesgo sistemático y el riesgo idiosincrático. Mientras que el último puede ser completamente diversificado, el primero no. En un mercado fragmentado, la incidencia de factores locales es relativamente mayor que en un mercado no fragmentado debido a que no se pueden diversificar completamente. Así, el riesgo sistémico presenta una relativa menor incidencia (Baele et al., 2004).

²Costola & Iacopini, 2023 identifica este problema en cuanto a la literatura avocada a la medición de fragmentación y propone un modelo de cointegración dinámico.

Índice general

1. Introducción	5
2. Revisión de Literatura	8
3. Metodología	14
3.1. Un modelo DCC-GARCH con múltiples quiebres estructurales	16
3.2. El algoritmo de segmentación de tres pasos	19
4. Resultados Empíricos	22
5. Chequeo de Robustez	31
6. Conclusión	33
7. Apéndice	36
7.1. Las funciones <i>score</i> del modelo DCC-GARCH	36
7.2. Notación formal del algoritmo de segmentación de tres pasos	38
7.3. Tablas y Figuras complementarias	39
Bibliografía	44



Capítulo 1

Introducción

En julio 2022, el Banco Central Europeo (BCE) lanzó, una vez más, un programa de compra de bonos soberanos con el objetivo de *neutralizar spreads injustificados de tasas*, i.e., el instrumento de protección de transmisión (TPI por sus siglas en inglés). En el contexto de suba de tasas de política monetaria, por primera vez desde 2011, el TPI está orientado a limitar fragmentación en la eurozona, donde los costos de financiamiento afrontados por los países miembros de la Unión Monetaria Europea (UME) comienzan a divergir. La última vez que el BCE anunció este tipo de instrumentos orientados a contener la fragmentación del mercado de bonos fue durante la Crisis de Deuda Soberana Europea (CDSE), cuando la heterogénea reacción de las tasas de bonos de los países miembros a la crisis de solvencia griega dio lugar a crisis de liquidez autocumplidas, i.e. no basadas en fundamentales subyacentes ([De Grauwe & Ji, 2012](#))¹. Sin embargo, con el objetivo de evaluar cuándo estas medidas anti-fragmentación deberían ser activadas, y para cuáles países en particular, explorar alternativas a indicadores destinados a la detección de

¹Los dos predecesores del TPI son los instrumentos *Securities Market Programme* (SMP) y *Outright Monetary Transactions* (OMT) establecidos en mayo 2010 y septiembre 2012 respectivamente. Ver [Bernoth et al. \(2022\)](#) para una comparación detallada entre estos tres instrumentos.

riesgos de fragmentación sigue siendo necesario².

El riesgo de fragmentación en el mercado de bonos soberanos se define como el riesgo de que curvas de tasas de interés diverjan entre países debido a que la cotización de estos activos no puede ser completamente explicada por factores globales (Baele et al., 2004). Bajo este escenario, los mercados están caracterizados por la ausencia de perfecta integración, donde la exposición a *shocks* puramente locales no puede ser enteramente diversificada geográficamente, impactando así en la *performance* de sus bonos soberanos. En contraposición, cuando el riesgo de fragmentación es bajo, uno esperaría que noticias idiosincrásicas tengan un efecto moderado en los retornos de los bonos, mientras que innovaciones comunes o globales deberían tener una relativa mayor incidencia. Por consiguiente, la observación de tasas de interés divergentes no es suficiente para afirmar la existencia de riesgos de fragmentación. En cambio, su identificación implica que el primer paso implique la diferenciación de fuentes de discrepancia de retornos, i.e. *shocks* locales vs. *shocks* globales (Ehrmann & Fratzscher, 2017).

Proponemos identificar el riesgo de fragmentación analizando las correlaciones dinámicas de los retornos de bonos soberanos de tres países pertenecientes a la UME que pueden estar sujetas a cambios estructurales desconocidos. Con este fin, aplicamos el algoritmo de segmentación de tres pasos (*TSSA* por sus siglas en inglés) presentado en Mugrabi (2023). Este algoritmo, basado en el test de distinctividad introducido por Oka & Perron (2018), permite la detección de múltiples y posiblemente distintos quiebres a

²El Consejo Regulator del BCE no ofrece una regla explícita sobre los indicadores específicos considerados con el fin de activar el TPI. En su lugar, la activación del TPI "va a estar basada en una evaluación integral del mercado y los mecanismos de transmisión, una evaluación de los criterios de elegibilidad y el criterio de que la activación de compras bajo el TPI esté alineada con los objetivos principales del BCE" (Ver ECB, 2022, Nota de Prensa).

lo largo de los parámetros del modelo DCC-GARCH³. De esta manera, las correlaciones condicionales están calculadas a partir de los residuos estandarizados obtenidos luego de controlar por innovaciones locales que afectan a la estructura de volatilidad de un país determinado. Como resultado, las correlaciones dinámicas estimadas toman en cuenta únicamente *shocks* comunes afectando a países emparejados, mientras que permanecen insesgadas producto de la posible presencia de heterocedasticidad condicional o quiebres estructurales en la varianza (ver respectivamente Engle, 2002 y Forbes & Rigobon, 2002). Considerando el período desde abril 2006 a octubre 2022, analizamos el riesgo de fragmentación en tres países de la UME, i.e. Francia, Italia y Grecia.

Esta tesis se divide de la siguiente manera. En el capítulo 2 se expone la Revisión de Literatura. El capítulo 3 describe la Metodología empleada, donde primero presentamos el modelo DCC-GARCH con múltiples quiebres estructurales y luego brindamos la intuición del *TSSA*. En los capítulos 4 y 5 presentamos los Resultados Empíricos y los Controles de Robustez del modelo respectivamente. Conclusiones en el capítulo 6. Finalmente, el Apéndice contiene guías metodológicas adicionales para llevar a cabo el *TSSA* y Tablas y Figuras complementarias.

Universidad de
San Andrés

³El algoritmo de Oka & Perron (2018) permite la detección de quiebres estructurales en parámetros de medias, mientras que la adaptación de Mugrabi (2023) permite la identificación de quiebres en los parámetros del modelo DCC-GARCH.

Capítulo 2

Revisión de Literatura

Desde la constitución de la UME, y particularmente luego de la CDSE, ha surgido un amplio interés por el riesgo de fragmentación de mercado entre sus países miembros. La revisión de la literatura da cuenta de que la investigación de riesgos de fragmentación dentro de una unión monetaria se basa en dos dinámicas opuestas que salieron a la luz en las últimas dos décadas en la UME. Por un lado, luego de la introducción de la moneda en común, cualquier posibilidad de competencia devaluatoria entre países ha sido eliminada, y con ello, una de las principales fuentes de discrepancia entre las tasas de bonos, i.e., la prima de riesgo de tipo de cambio, fue eliminada (Baele et al., 2004). Como resultado, los primeros años de la unión monetaria han sido caracterizados por una fuerte convergencia entre tasas a lo largo de países con divergentes características macroeconómicas y riesgos de solvencia, no solo en términos de su nivel sino también en sus reacciones a innovaciones (Angeloni & Ehrmann, 2003). Por otro lado, la CDSE probó que la descentralización de la administración de la deuda pública puede dar lugar a fragmentación cuando la política monetaria es centralizada como es en el caso de la

UME. Debido a la ausencia de un prestamista de última instancia¹, los países miembros de la UME no pueden dar garantía a sus tenedores al 100 % que contarán con la liquidez necesaria para cancelar sus bonos al vencimiento. Por consiguiente, el riesgo de que los gobiernos puedan quedarse sin liquidez suficiente, crea el potencial de crisis de liquidez autocumplidas, i.e. no basadas en cambios en los fundamentales subyacentes (De Grauwe & Ji, 2013)². Por consiguiente, desde el inicio de la CDSE, la divergencia entre tasas de bonos dentro de la UME alcanzó niveles altos sin precedentes, especialmente entre el núcleo y la periferia, y nunca han retornado a los niveles previos. La era de fragmentación había comenzado (Candelon et al., 2022)³.

Sumado al potencial de crisis de liquidez autocumplidas, el riesgo de quiebre en la UME implica el riesgo subsecuente de que algunos activos denominados en euros sean devaluados o redenominados en una nueva moneda nacional (De Santis, 2019). Adicionalmente, la fragmentación en el mercado de bonos en la UME implica varios desafíos en otros mercados. Zaghini (2016) evalúa el riesgo de fragmentación en el mercado de bonos corporativos a partir de cotizaciones heterogéneas entre países no explicadas por cambios en los determinantes fundamentales del riesgo de crédito que impactan en el rendimiento de los bonos soberanos. Angelini et al. (2014) demuestra que las divergencias en las tasas soberanas tiene un primer efecto en el riesgo de solvencia de bancos domésticos dando lugar a espirales negativos autocumplidos que potencian dificultades soberanas. Final-

¹La cláusula de *no-bailout* del Tratado estipula que *ni la Comunidad ni los Países Miembros son responsables, o deban asumir, las deudas incurridas por otros Países Miembros.*

²Este problema no existe en países con política monetaria independiente donde los gobiernos pueden emitir deuda en su propia moneda (De Grauwe & Ji, 2013).

³Estos dos grupos de países están caracterizados por fundamentales macroeconómicos y riesgos de solvencia divergentes y son comúnmente categorizados por la literatura como periferia, i.e. el grupo de mayor riesgo, y núcleo, i.e. el grupo más seguro (Campos & Macchiarelli, 2016).

mente, otros trabajos se enfocan en las implicancias de los riesgos de fragmentación en los mecanismos de transmisión de política monetaria a través de los mercados overnight no garantizados, ([Garcia-de Andoain et al., 2014](#)), el mercado prestamista minorista ([Al-Eyd & Berkmen, 2015](#)) y el pass-through de tasas de interés ([Horvath et al., 2018](#)).

La literatura orientada a analizar la fragmentación del mercado de bonos soberanos se ha dedicado a desarrollar diferentes medidas de fragmentación dado que no existe un indicador que sea directamente observable⁴. En una etapa temprana de la literatura, [Baele et al. \(2004\)](#) aproximan fragmentación como la ausencia de perfecta integración de mercado medida como la inversa del coeficiente beta entre el rendimiento de un bono de un país dado y el retorno de un activo representativo de un mercado completamente integrado, i.e. únicamente influenciado por factores globales, mientras que los residuos del modelo representan *shocks* locales. En particular, los autores argumentan que el bono soberano a 10 años de Alemania es una buena referencia de mercado perfectamente integrado. Más adelante, [Ehrmann & Fratzscher \(2017\)](#) implementan un modelo Vector Autorregresivo (VAR) donde la fragmentación es detectada cuando encuentran cambios negativos en los componentes de la matriz rotación. Los autores identifican regímenes endógenamente cuando los residuos del modelo VAR se encuentran al menos una desviación estándar por encima de la media a lo largo de todo el período de muestra considerado. Sin embargo, debido al problema de sobre-identificación, necesitan asumir que la matriz de rotación es estable a lo largo de los regímenes. Recientemente, [Candelon et al. \(2022\)](#) proponen un modelo GVAR donde cambios negativos en los

⁴Según [Baele et al. \(2004\)](#), el indicador más efectivo para medir la ausencia de perfecta integración de mercado debería estar basado en la ley de único precio. Por consiguiente, medir riesgos de fragmentación implicaría medir el no cumplimiento de la ley de único precio ([Zaghini, 2016](#)). Sin embargo, en la práctica, la ley de único precio puede ser validada únicamente en instrumentos que sean listados o cotizados en dos o más mercados a la vez. Así, para chequear la validez de esta ley no hay otra alternativa que desarrollar medidas alternativas ([Baele et al., 2004](#)).

elementos de la matriz de carga (*weighted – matrix*) están asociados a indicios de fragmentación. En particular, estos componentes surgen de estimar el GVAR a partir de la segunda componente principal de los *spreads* soberanos, i.e. la varianza cross-seccional dejada explicada por factores globales. Los autores identifican los regímenes del modelo de manera narrativa (exógenamente).

Como puede ser notado, con el objetivo de medir fragmentación, la literatura citada en el párrafo anterior captura dependencia cross-seccional causada por factores globales a partir de la estimación de la estructura de la media de los retornos. Sin embargo, [Baele et al. \(2004\)](#) destacan que este tipo de modelos, incluso si permiten que los betas sean diferentes a través de regímenes, asumen que los coeficientes permanecen constantes dentro de los sub-períodos. Por consiguiente, los autores proponen un indicador alternativo para medir cuán lejos un mercado se encuentra de estar completamente integrados basándose en la dispersión cross-seccional de los *spreads* de los retornos. Así, cuanto menor sea el grado de correlación entre un mercado dado y otro perfectamente integrado a los factores globales, mayor será su grado de dispersión cross-seccional, y por ende se esperarí que sus retornos diverjan a lo largo del tiempo.

Asimismo, la dependencia cross-seccional puede ser capturada a través de la estimación de covarianzas dinámicas ([Ng, 1991](#)) o pruebas de cointegración ([Mehmet et al., 2014](#)). En cuanto a este último, [Costola & Iacopini \(2023\)](#) han propuesto medir el riesgo fragmentación empleando un modelo de *regime – switching* de cointegración para capturar la probabilidad de existencia de dependencia cross-seccional de largo plazo. Los autores infieren la ausencia de riesgo de fragmentación cuando las tasas de bonos de núcleo y periferia poseen una probabilidad alta de compartir una tendencia de largo plazo en común. Sin embargo, se ha demostrado que los test de co-integración pueden ser altamente sensibles a cambios estructurales en la tendencia estocástica de largo plazo, dando lugar al sobre-rechazo de la hipótesis de co-integración ([Campos & Macchiarelli, 2016](#)).

Medir dependencia cross-seccional a través de la estructura de covarianza dinámica reconcilia tres hechos estilizados en relación a los retornos: i) media cero de los retornos, ii) volatilidad dependiente del tiempo (iii) correlaciones dependientes del tiempo (Engle, 2002). Consecuentemente una amplia serie de modelos GARCH multivariados ha sido propuesta para estimar la covarianza dinámica de los retornos (Bauwens et al., 2006). En particular, la ventaja del modelo DCC-GARCH reside en la intuitiva y simple separabilidad entre las estructuras de volatilidad y la de correlación (Hafner & Herwartz, 2008). Sin embargo, dado que eventos de fragmentación están asociados a períodos de *stress* de mercado que toman lugar en períodos de tiempo desconocidos (Costola & Iacopini, 2023), es esperable que ocurran quiebres estructurales afectando a los parámetros del modelo (Ehrmann & Fratzscher, 2017). En este sentido, Forbes & Rigobon (2002) advierten que la estimación de correlaciones puede estar sesgada por la presencia de quiebres estructurales que afectan a la varianza. Adicionalmente, Adams et al. (2017) demuestran que es necesario tener en cuenta quiebres estructurales cuando se utilizan modelos DCC-GARCH para evitar correlaciones dinámicas espúreas que pueden dar lugar a estimaciones erróneas. Finalmente, Hillebrand (2005) y Aielli (2013) probaron, respectivamente, que los quiebres estructurales pueden dar lugar a la sobre-estimación de la persistencia en la varianza y correlación.

Técnicas que permitan la identificación de quiebres estructurales afectando a subconjuntos específicos de parámetros han sido ampliamente exploradas. Bajo el supuesto de que las fechas de quiebre son desconocidas, la estimación parcial muestral (partial sample estimation or *PSE* en inglés), introducida por Andrews (1993), permite la detección de un quiebre único en un subconjunto de parámetros⁵. Más adelante, Bai & Perron (1998) extienden el análisis al caso de múltiples quiebres estructurales y presen-

⁵Ellos comparan el *SupLM*, el *SupLR* y el *SupWald*, y encuentran que el *SupLM* posee la potencia de prueba más alta.

tan el procedimiento de *repartición*. Sin embargo, [Oka & Perron \(2018\)](#) nota que, hasta ese momento, los procedimientos estaban basados en el supuesto de que un grupo de parámetros es afectado por un quiebre común mientras que se asumía que el resto de los parámetros no presentarían ningún quiebre a lo largo de todo el período. Así, propone un método de *bootstrap* que simula una cantidad suficientemente grande de particiones para determinar si los quiebres detectados pueden ser considerados comunes o distintos entre los coeficientes de medias en modelos lineales. Sin embargo, dado que los autores utilizan el estadístico *Supremum Likelihood Ratio* (*SupLR*), este procedimiento puede ser computacionalmente intensivo ([Estrada et al., 2015](#)), i.e. el *LR* requiere la estimación del modelo restringido (sin quiebres) y no restringido. A su vez, [Andrews \(1993\)](#) ha demostrado que el *SupLM* posee una potencia de prueba más alta que el *SupLR*. Luego, [Mugrabi \(2023\)](#) propone el *TSSA* para estimar quiebres estructurales basado en el procedimiento de [Oka & Perron \(2018\)](#) aunque empleando el *SupLM* estadístico. De esta manera, el procedimiento requiere la estimación de los parámetros del modelo restringido únicamente a partir de los quiebres encontrados previamente y no para cada partición de la muestra. Finalmente, el *TSSA* es aplicado particularmente sobre el modelo DCC-GARCH con una potencia no trivial, i.e. las verdaderas posiciones de quiebres son estimadas con una potencia mayor al 40% para cada parámetro del modelo DCC-GARCH.

Capítulo 3

Metodología

Inferimos el nivel de riesgo de fragmentación a través del grado de correlación dinámica entre retornos de bonos de un país dado y una activo representativo de un mercado perfectamente integrado a los factores globales. Así, correlaciones dinámicas cercanas a cero indicarían la presencia de riesgo elevado de fragmentación. Siguiendo a [Baele et al. \(2004\)](#), consideramos el bono soberano alemán a 10 años como referencia de un mercado perfectamente integrado, denominado a partir de ahora *referencia*¹.

Estimamos las correlaciones dependientes del tiempo a través del modelo DCC-GARCH introducido por [Engle \(2002\)](#). La ventaja de este modelo yace en la descomposición de la matriz de covarianza entre la estructura de volatilidad y la de correlación. Así, podemos diferenciar innovaciones locales que afectan a la volatilidad de un cierto país de innovaciones relacionadas a la interacción entre el país considerado y un mercado perfectamente integrado. Esto es posible gracias a la estimación DCC-GARCH en dos pasos. En el primer paso se estiman las volatilidades individuales como función de *shocks* locales, luego, se ajustan los retornos con las volatilidades estimadas para obtener los

¹Adicionalmente encontramos que otros estudios utilizan el bono del Tesoro de Estados Unidos a 10 años como referencia de factor global ([Miranda-Agrippino & Rey, 2020](#)) o el spread de bonos de largo plazo corporativos entre Baa y Aaa para capturar aversión global al riesgo ([Favero, 2013](#)).

residuos estandarizados. Estos residuos, se asumen correlacionados, i.e. conducidos por innovaciones que no pueden ser explicadas por *shocks* puramente locales. En una segunda etapa, se estima la estructura de correlación a partir de estos residuos estandarizados. Así, las correlaciones resultantes van a estar determinadas por las respuestas comunes a innovaciones que afectan a un país determinado y un mercado perfectamente integrado, reflejando así el grado de sincronización entre un cierto mercado y los factores globales.

Permitimos las posibilidades de que los parámetros del modelo estén sujetos a quiebres múltiples y desconocidos que (i) pueden ser comunes a un grupo de parámetros y/o (ii) pueden ocurrir en momentos diferentes del período considerado. Para ello empleamos el *TSSA* dirigido a encontrar este tipo de quiebres en el modelo DCC-GARCH presentado en Mugrabi (2023). Este algoritmo está basado en dos procedimientos de prueba. Primero, el procedimiento de *repartición* propuesto por Perron et al. (2006) que puede detectar quiebres múltiples que impactan en un parámetro determinado. Segundo, la prueba de *distintividad* introducida por Oka & Perron (2018) dirigido a inferir si los quiebres encontrados en distintos parámetros ocurren simultáneamente (son comunes) o si suceden en distintos momentos del período muestral (distintos). En lugar de utilizar el estadístico *SupLR* como lo hacen Perron et al. (2006) y Oka & Perron (2018), el *TSSA* utiliza el *SupLM* formulado en Andrews (1993)². La utilización del *SupLM* posee dos ventajas principales. Primero, Andrews (1993) demuestra que el *SupLM* posee la mayor potencia asintótica en comparación con *SupLR* y *SupWald*. Segundo, el *SupLM*, a diferencia de los otros estadísticos, requiere la estimación de las funciones *score* del modelo restringido, i.e. sin quiebres estructurales. De esta manera, la estimación de los parámetros se debe hacer a partir del último quiebre encontrado, y no para cada partición de la muestra donde se intenta encontrar un quiebre, reduciendo así los costos

²El procedimiento de prueba propuesto en Andrews (1993) admite únicamente la presencia de un quiebre estructural.

computacionales.

Luego de detectar cualquier combinación de quiebres comunes o distintos, dentro de los regímenes identificados, estimamos los parámetros del modelo DCC-GARCH. Así, se previene que las resultantes correlaciones dinámicas estimadas estén sesgadas por quiebres estructurales que afectan a la estructura de volatilidad (Forbes & Rigobon, 2002). A su vez, prevenimos estimaciones erróneas causadas por la presencia de quiebres en los parámetros de la correlación dinámica (Andreou & Ghysels, 2003).

Esta sección se estructura de la siguiente manera. Primero presentamos el modelo DCC-GARCH que admite la presencia de quiebres múltiples en sus parámetros. Esto es, presentamos la adaptación del modelo de Engle (2002) para que admita el procedimiento de *repartición* de Perron et al. (2006). Luego, resumimos los aspectos claves del *TSSA*. La notación formal del algoritmo es presentada en el apéndice.

3.1. Un modelo DCC-GARCH con múltiples quiebres estructurales

Siguiendo a Engle (2002), considere un vector y_t de N retornos de activos diarios para $t = 1, \dots, T$. Se asume que el vector de dimensión N sigue una distribución normal con media cero y covarianza dinámica Ω_t .

La matriz de covarianzas puede ser descompuesta de la siguiente manera:

$$\Omega_t = V_t R_t V_t,$$

donde V_t^2 es una matrix diagonal representando la varianza condicional y R_t es la correlación dinámica, i.e. matriz simétrica con diagonal uno.

La especificación estadística del modelo es:

$$V_t^2 = W + A \circ y_{t-1} y_{t-1}' + B \circ V_{t-1}^2,$$

$$\epsilon_t = V_t^{-1} y_t,$$

$$Q_t = \Omega + \alpha \epsilon_{t-1} \epsilon_{t-1}' + \beta Q_{t-1},$$

$$R_t = \text{diag}(Q_t)^{-1} Q_t \text{diag}(Q_t)^{-1},$$

$$\Omega = R(1 - \alpha - \beta),$$

donde \circ es el producto Hadamard. El término de error (ϵ_t) es ajustado por volatilidad pero correlacionado. Los parámetros de la varianza (W , A and B) son matrices diagonales, el término constante de la correlación (R) es simétrico con unos fuera de la diagonal y sus términos dinámicos, α y β , son números escalares. Para que R_t sea positiva definida (pd) basta con que Q_t sea pd, caso que se cumple si $\alpha \geq 0$, $\beta \geq 0$, $\alpha + \beta < 1$ y R es pd.

Para un país dado $n \in 1, 2, \dots, N$, se asume que la volatilidad depende de las innovaciones locales del día anterior ($y_{t-1,n}^2$). Así, el efecto de *shocks* locales en la volatilidad está capturado por el elemento n de la diagonal de la matriz A . Nótese que, los residuos estandarizados ($\epsilon_{t,n} = V_{t,n}^{-1} y_{t,n}$) son conducidos por innovaciones que no pueden ser explicadas por *shocks* locales. Como resultado, las correlaciones están determinadas por el efecto de noticias comunes afectando a dos activos diferentes ($\epsilon_{t,n} * \epsilon_{t,m}$ con $m \neq n$).

Así como en el procedimiento de *repartición* de Perron et al. (2006), cada parámetro individual $\psi \in \Psi = [W, A, B, R, \alpha, \beta]$ está sujeto a cierto número (desconocido) de quiebres estructurales $j_\psi = 1, \dots, \lambda_\psi$. Cada quiebre toma lugar en un momento de tiempo desconocido $T_{\psi,j}$, donde la convenciones $T_{\psi,0} = 1$ y $T_{\psi,\lambda_\psi+1} = T$ son usadas.

Con el fin de obtener estimaciones consistentes, Perron et al. (2006) asumen que los quiebres que afectan a un parámetro dado (ψ) son asintóticamente distintos y no se

encuentran en los extremos de la muestra. Así, la verdadera posición de un quiebre se encuentra en una proporción de la muestra ($\pi_{\psi,j}^*$) y dentro de un intervalo dado por un recorte, en inglés *trimming-window*, $\pi_{\psi,j}^* \in (\pi_0, 1 - \pi_0)$. A continuación, las fechas de quiebre están dadas por:

$$T_{\psi,j} = T\pi_{\psi,j}^*,$$

donde $0 < \pi_{\psi,1}^* < \pi_{\psi,2}^* < \dots < \pi_{\psi,\lambda_\psi}^* < 1$. Nótese que, a medida que el tamaño muestral aumenta, todos los segmentos se incrementan en la misma proporción.

Para cada quiebre $j=1,2,\dots,\lambda_\psi$, la varianza condicional se expresa como:

$$V_t = W + D_{t,\pi_{W,j}^*} \circ \acute{W}_j + A \circ y_{t-1} y'_{t-1} + D_{t,\pi_{A,j}^*} \circ \acute{A}_j \circ y_{t-1} y'_{t-1} + B \circ V_{t-1}^2 + D_{t,\pi_{B,j}^*} \circ \acute{B}_j \circ V_{t-1}^2,$$

donde las variables *dummy* ($D_{t,\pi_{\phi,j}^*}$) son matrices NxN con diagonal uno cuando $T_{\psi,j-1} + 1 < t < T_{\psi,j}$.

Análogamente, la correlación condicional está dada por:

$$Q_t = (R + R \circ D_{t,\pi_{R,j}^*}) (1 - \alpha - \beta - (\acute{\alpha} + \acute{\beta}) D_{t,\pi_{\alpha,\beta,j}^*}) + \alpha \epsilon_{t-1} \epsilon'_{t-1} + \beta Q_{t-1} + (\acute{\alpha} \epsilon_{t-1} \epsilon'_{t-1} + \acute{\beta} Q_{t-1}) D_{t,\pi_{\alpha,\beta,j}^*},$$

donde $D_{t,\pi_{R,j}^*}$ es una matriz con diagonal cero y elementos fuera de la diagonal igual a uno cuando $T_{\psi,j-1} + 1 < t < T_{\psi,j}$. De igual manera, $D_{t,\pi_{\alpha,\beta,j}^*}$ corresponde a una *dummy* escalar.

Nótese que cualquier parámetro ψ puede presentar λ_ψ quiebres distintos y que cada fecha de quiebre $T_{\psi,j}$ puede ser distinta o simultánea para cualquier grupo de parámetros $\Psi \in [W, A, B, R, \alpha, \beta]$.

3.2. El algoritmo de segmentación de tres pasos

En el primer paso, el *TSSA* está dirigido a detectar quiebres secuenciales sobre cada parámetro individual de la varianza ($\theta = [W, A, B]$) aplicando el proceso de *repartición* basado en Perron et al. (2006). Una vez finalizado el proceso de detección de quiebres en cada uno de los parámetros, en una segunda etapa, emplea la prueba de *distintividad* de Oka & Perron (2018) para determinar si los quiebres encontrados en dos o más parámetros yacen suficientemente cerca. El último paso está dirigido a encontrar quiebres en la estructura de correlación ($\phi = [R, \alpha, \beta]$), tomando en cuenta los quiebres de la varianza. Esto es posible gracias a las dos etapas de estimación del proceso DCC-GARCH, donde en la segunda etapa, la correlación se estima utilizando los residuos estandarizados con los parámetros de volatilidad. El algoritmo, en vez de estandarizar los residuos con la varianza estimada a través de todo el período muestral (como en Engle & Kroner, 1995), utiliza la varianza apilada entre los regímenes encontrados en los pasos uno y dos. Con esta varianza apilada, repite los pasos uno y dos para encontrar quiebres estructurales en ϕ . La notación formal del algoritmo es reportada en el Apéndice.

Contrariamente a Perron et al. (2006) y Oka & Perron (2018), donde el estadístico *SupLR* es utilizado, el *TSSA* se basa en el *SupLM* de Andrews & Ploberger (1994). Sin embargo, el *SupLM* original es adaptado para permitir la existencia de quiebres sucesivos $j = 1, 2, \dots, \lambda_{\psi_1}$, dando lugar al *SupLM* $_{\psi_1, j}$. El estadístico está dado por:

$$LM_{\psi_1, j}^*(\pi) = \frac{1}{\sqrt{\tau_{\psi, j}}} \sum_{[T_{\psi, j-1} + \tau_{\psi, j} \pi]}^T \frac{\partial l_t(\psi_1, \psi_2)}{\partial \psi_1} \times \left[I_T^{-1}(\pi)_{pre, j} + I_T^{-1}(\pi)_{post, j} \right] \\ \times \frac{1}{\sqrt{\tau_{\psi, j}}} \sum_{[T_{\psi, j-1} + \tau_{\psi, j} \pi]}^T \frac{\partial l_t(\psi_1, \psi_2)}{\partial \psi_1},$$

$$SupLM_{\psi_1, j} = Sup_{\pi \in (\pi_0, 1 - \pi_0)} [LM_{\psi_1, j}^*(\pi)],$$

done ψ_1 son los parámetros bajo evaluación, π se distribuye uniformemente en $[\pi_0, 1 -$

$\pi_0] \subset \mathbb{R}^M$ y $T_{\psi,j-1} + \tau_{\psi,j}\pi$ es una fecha aleatoria que puede tomar lugar desde el quiebre anterior ($j - 1$) hasta el final del intervalo muestral recortado $(1 - \pi_0)T$. Seleccionamos el recorte en $\pi_0 = 0,25$ siguiendo la convención común (Hansen & Seo, 2002). Las funciones *score* ($\frac{\partial \ln(\psi_1, \psi_2)}{\partial \psi_1}$) son presentadas en el Apéndice. Finalmente, $I_T^{-1}(\pi)_{pre,j}$ y $I_T^{-1}(\pi)_{post,j}$ pueden ser aproximadas como la suma de los productos cruzados de las primeras derivadas de las funciones *core* a lo largo del período considerado (ver Hafner & Herwartz, 2008 o Andrews & Ploberger, 1994).

Nótese que el $SupLM_{\psi_1,j}$ es definido como el valor máximo del estadístico $LM_{\psi_1,j}^*$ a lo largo de todas las posibles particiones muestrales consideradas M . Especificamos la cantidad de particiones como el 10% del (remanente) período muestral, i.e. $M = 0,1 \times T$.

La posición de los quiebres está dada por la partición muestral donde se ha encontrado que el $SupLM$ toma valores mayores a los valores críticos (*qcrit*) reportados en Andrews (2003):

$$\widehat{\pi}_{\psi_1,j} = \underset{\pi_0 < \pi < 1 - \pi_0}{argmax} LM_{\psi_1,j}^*(\pi).$$

El *TSSA* empieza con la detección de quiebres en cada uno de los parámetros de la varianza ($\theta = [W, A, B]$). Para ello, realiza $L = 1,000$ replicaciones y en cada una de ellas peticiona M veces el período de muestra. Para cada replicación ($l \in 1 : L$) conforma M variables uniformemente distribuidas en $\pi \in (\pi_0, 1 - \pi_0)$. Luego, computa el $LM_{\psi_1,j}^*(\pi)^l$ en cada partición de muestra (π) y para cada replicación (l)³. De esta manera, extiende la búsqueda a numerosas posibles locaciones para cada replicación de las simulaciones. Luego, P se define como el número total de replicaciones para las cuales un quiebre fue detectado, i.e. $SupLM_{\psi_1,j}^l > qcrit$. Finalmente, definimos $\varphi = 0,95$ como la potencia deseada (no trivial). Así, inferimos la existencia de un quiebre cuando es encontrado al menos en el 95% de las 1,000 replicaciones, i.e. si $\frac{P}{L} > \varphi$.

³Para simplificar notación a partir de aquí eliminamos el sufijo en ψ_1 .

El segundo paso del *TSSA* recae en la detección de *distintividad*. Si $\frac{P}{L} > \wp$ se cumple para más de un parámetro, va a determinar si las fechas de quiebre estimadas son significativamente similares o diferentes. Primero, toma las posiciones de quiebre estimadas $(\widehat{\pi}_{\psi,j}^l)_{l \in P}$ cuando $\frac{P}{L} > \wp$. Luego, colecta los pares y quiebres que cumplen esta condición $(\psi, j) \subseteq (1, \dots, s) \times (1, \dots, \lambda_\psi)$. Así, crea G grupos de pares (ψ, j) disjuntos, $\mathcal{G}_1, \mathcal{G}_2, \dots, \mathcal{G}_G \subseteq \{(1, \dots, s) \times (1, \dots, \lambda_{total})\}$ tal que, dentro de cada grupo \mathcal{G}_g , todos los parámetros comparten el mismo quiebre. Los quiebres significativamente distintos son denotados por T_g donde $g = 1, \dots, G$.

Para conformar los grupos \mathcal{G}_g , el algoritmo construye intervalos de confianzas al 95% ($CI_{\psi,j}$) sobre las posiciones de quiebre encontradas $(\widehat{\pi}_{\psi,j}^l)_{l \in P}$. Tomando en cuenta todas las posibles combinaciones entre pares (ψ, j) , si ninguno de los $CI_{\psi,j}$ se superpone, conforma cada grupo \mathcal{G}_g con cada par individual. Nótese que en este caso, la cantidad de grupos G resulta igual al total de quiebres encontrados $\lambda_{total} = \sum_{\psi} \lambda_{\psi}$. Si dos o más $CI_{\psi,j}$ se superponen, agrupa los correspondientes pares en el mismo grupo \mathcal{G}_g .

La posición de quiebres simultáneos $\widehat{\pi}_g$ se computa como el promedio de los $CI_{\psi,j}$ entre los pares (ψ, j) pertenecientes al mismo grupo g . Finalmente, la colección de quiebres distintos es $\widehat{\pi}_g$ para $g=1,2,..G$.

En el último paso, el *TSSA* está dirigido a encontrar quiebres en la estructura de correlación. Para ello utiliza la volatilidad dinámica apilada entre los regímenes encontrados en los pasos previos. Asumamos que encontramos una cantidad de quiebres sucesivos en la varianza igual a G_θ , así, los parámetros estimados dentro de estos sub-períodos son $\bar{\theta} = [\theta_1, \theta_2, \dots, \theta_{G_\theta}]$. A continuación, en el último paso se utiliza la volatilidad apilada en el proceso de estimación de la estructura de correlación. De esta manera, las correlaciones dinámicas son estimadas a partir de residuos estandarizados ajustados por quiebres encontrados en la varianza, i.e. $\epsilon = V_t(\bar{\theta})^{-1}y_t$.

Capítulo 4

Resultados Empíricos

Consideramos los retornos diarios del índice FTSE World Government Bond correspondiente a los bonos soberanos de largo plazo denominados en moneda extranjera¹ para Alemania, Francia, Italia y Grecia. La lista de índices tomados de Bloomberg es reportada en el Apéndice, Tabla 7.1. Tomando el período desde 2006/01/04 a 2022/10/12, contamos con 4,375 observaciones².

Encontramos que tres quiebres distintos afectan a los parámetros de la estructura de covarianzas. El primer quiebre es el 2010/04/09 con una desviación estándar de 30 días impactando en todos los términos de la varianza (W, A y B) y el término constante de la correlación (R). El segundo y tercer quiebre, i.e. 2013/05/31 (+/- 24 días) y 2015/10/12 (+/-20 días), alteran únicamente la varianza.

En la Figura 4.1 ilustramos los retornos diarios de los cuatro bonos considerados y las distintas fechas de quiebre encontradas. En el gráfico, se puede notar que, antes de

¹Seleccionamos índices denominados en moneda extranjera para reducir el efecto de volatilidad en los retornos originada por la expectativa de depreciaciones.

²Períodos previos no son considerados dado que el índice FTSE para Grecia se encuentra disponible a partir de 2006/01/04.

2010/04/09, los cuatro retornos crecen a una tasa similar, i.e. en promedio $+0.35\%$ anual. A comienzos de 2010, los retornos de los bonos griegos presentan una destacable caída (-51% desde 2010/04/09 a 2013/05/31), mientras que el resto se mantiene en territorio positivo aunque con cierta volatilidad. A partir de inicios de 2013, de la ilustración se puede inferir una volatilidad más contenida para Alemania, Francia e Italia, mientras que los bonos griegos presentan retornos prácticamente nulos³. A continuación, se puede observar el efecto en los retornos en el momento en que Grecia entra en *default* soberano en junio 2015, mientras que en octubre 2015, comienzan a recuperarse.



³Esto se debe a que en ciertos períodos el valor comercializado en el mercado de valores es insignificante y el FTSE no reporta actualizaciones en su precio.

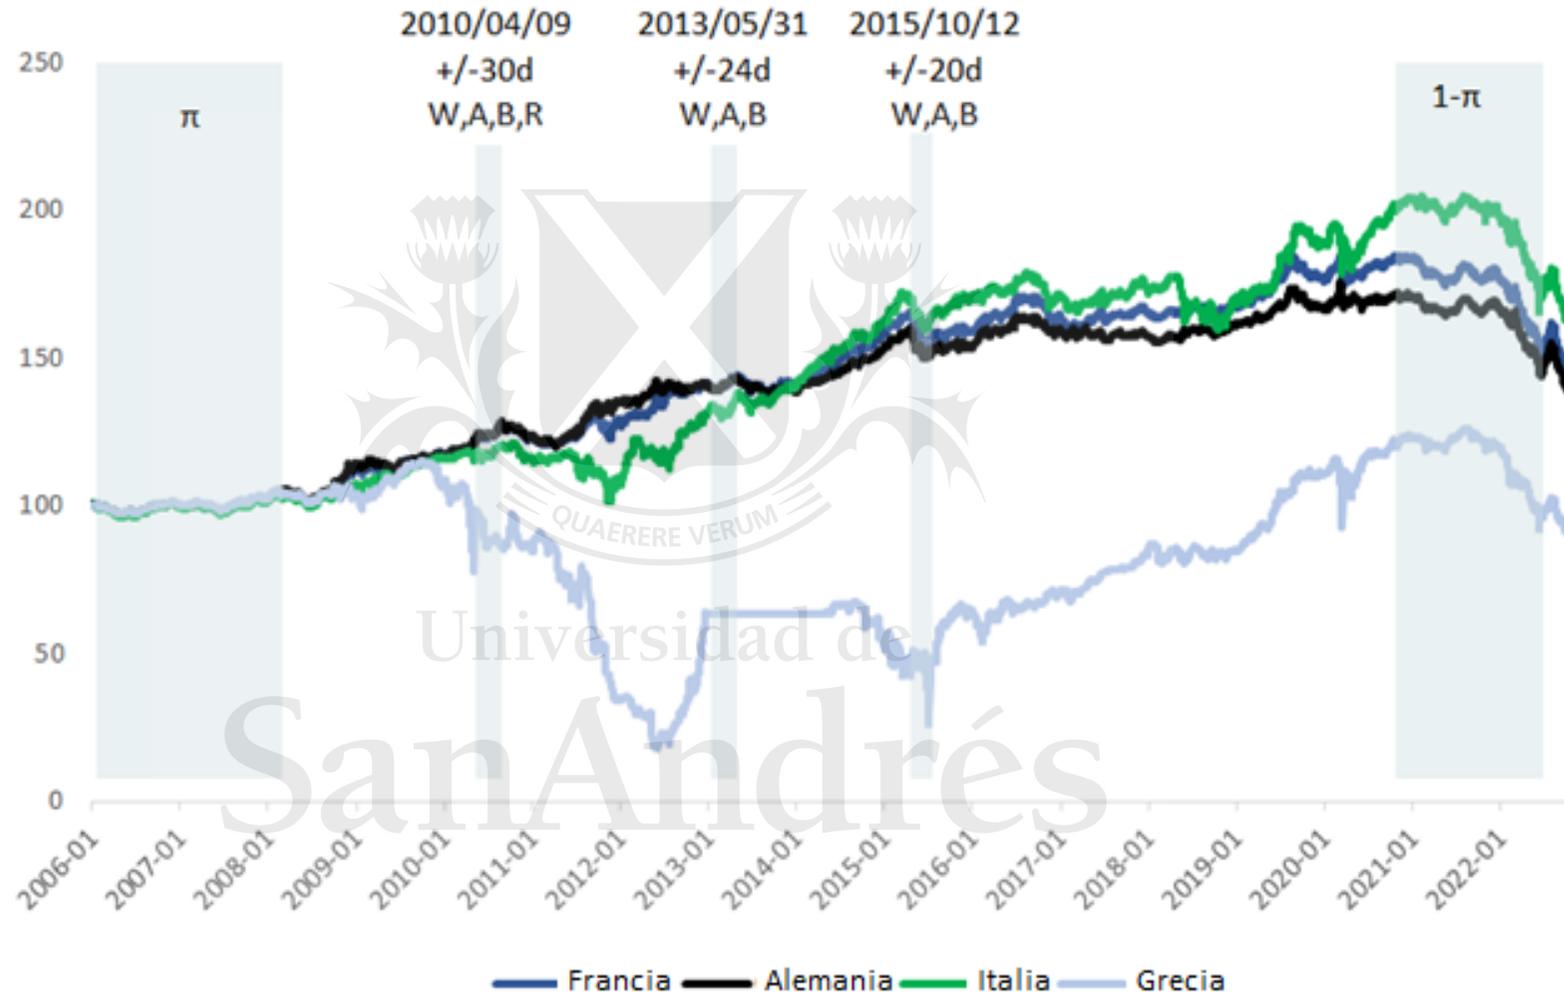


Figura 4.1: Retornos diarios y fechas de quiebre detectadas

Podemos asociar los quiebres encontrados y los cuatro regímenes resultantes con las siguientes fechas críticas. El primer régimen incluye la Crisis Financiera Global de 2007-2008. El segundo empieza con el estallido de la CDSE, i.e. Grecia solicita asistencia financiera externa a principios de 2010 y recibe el primer paquete de rescate UE-FMI en mayo 2010. El tercer régimen empieza en mayo 2013, coincidiendo con la recuperación de la confianza de los inversores en los países de la periferia, seguido por el anuncio del programa *Outright Monetary Transactions* (OMT) dirigido a mitigar la fragmentación del mercado y las exitosas licitaciones de deuda soberana a lo largo de la euro zona (Al-Eyd & Berkmen, 2013⁴). El último régimen es detectado a partir octubre 2015 e incluye el programa de compra de activos públicos *Public Sector Purchase Programme* (PSPP) dirigido al mercado de bonos soberano (Andrade et al., 2016). Sin embargo, otros *shocks* locales toman lugar, i.e. la recuperación de bonos griegos en octubre 2015 luego del reporte favorable emitido por el FMI alegando el éxito de reformas económicas (IMF, 2017), la turbulencia de mercado ocasionada por el *Brexit* en junio 2016 (Belke et al., 2018) y la crisis política italiana en mayo 2018 (Sapir, 2018).

En la Tabla 4.1 reportamos los parámetros estimados entre los cuatro regímenes detectados a través del modelo DCC-GARCH. La interpretación de los términos constantes de la correlación país-referencia, permite comparar niveles de riesgo de fragmentación. En la Figura 4.2 se puede observar cómo la evolución de la correlación dinámica está influenciada por sus términos constantes estimados.

En cuanto a la interpretación de los tres quiebres comunes a todos los parámetros de la varianza observamos que, durante el período de la CDSE, la volatilidad de los retornos de bonos alemanes es más sensible a sus *shocks* locales ($\Delta A_{Alemania} = +887\%$) y menos sensible a su volatilidad pasada ($\Delta B_{Alemania} = -32\%$). Sin embargo, en los sub-

⁴Los autores encuentran que en marzo 2013 el riesgo de fragmentación se reduce y lo atribuyen al eventos anteriormente mencionados.

Tabla 4.1: Resultados Empíricos - Parámetros estimados para los cuatro regímenes encontrados

	[1] [2006/01/04- 2010/04/09]	[2] [2010/04/09- 2013/05/31]	[3] [2013/05/31- 2015/10/12]	[4] [2015/10/12- 2022/10/12]
Parámetros de Varianza				
$W_{Francia}$	0.0000	0.0000	0.0000	0.0000
$A_{Francia}$	0.0360	0.0762***	0.0277	0.0488
$B_{Francia}$	0.9611****	0.9017****	0.9651****	0.9467****
W_{Italia}	0.0000	0.0001****	0.0000	0.0000
A_{Italia}	0.0356	0.3702****	0.0623*	0.1499**
B_{Italia}	0.9618****	0.64981****	0.8938****	0.8380****
W_{Grecia}	0.0000	0.0000	0.0000	0.0000
A_{Grecia}	0.0742	0.5022****	0.9997**	0.1683**
B_{Grecia}	0.9323****	0.6706****	0.5793****	0.8374****
$W_{Alemania}$	0.0000	0.0000	0.0000	0.0000
$A_{Alemania}$	0.0375*	0.3707****	0.0316	0.0518
$B_{Alemania}$	0.9587****	0.6499****	0.9652****	0.9388***
Parámetros de Correlación				
α	0.0644****	0.0412****	0.0307****	0.0649****
β	0.9343****	0.9563****	0.9507****	0.9192****
$R_{Francia,Alemania}$	0.9924	0.6907 [-30 %]	0.9227 [+34 %]	0.9088 [-2 %]
$R_{Italia,Alemania}$	0.9121	0.2681 [-71 %]	0.2832 [+6 %]	0.4434 [+57 %]
$R_{Grecia,Alemania}$	0.8721	-0.2066 [-124 %]	0.3073 [-249 %]	0.4147 [+35 %]
$R_{Francia,Italia}$	0.9027	0.1244 [-85 %]	0.5170 [+316 %]	0.5901 [+14 %]
$R_{Francia,Grecia}$	0.7979	-0.0389 [-105 %]	0.0262 [-167 %]	0.2301 [+779 %]
$R_{Italia,Grecia}$	0.7635	-0.1584 [-121 %]	-0.0564 [-64 %]	0.1306 [-332 %]

Notas: p-values: * $\leq 0,05$, ** $\leq 0,01$, *** $\leq 0,001$ y **** $\leq 0,0001$.

siguientes regímenes, este parámetro de volatilidad vuelve a valores previos a la CDSE. Encontramos que Italia y Grecia presentan una elevada varianza en la volatilidad luego de la CDSE ($A_{Italia}=0.3702$ y $A_{Grecia}=0.5022$). Sin embargo, durante el tercer régimen, niveles inferiores son observados en Italia, mientras que Grecia logra mitigar el impacto de *shocks* locales en la volatilidad de sus bonos. Finalmente, en el último régimen, esta situación se revierte y la volatilidad de bonos italianos aparece más afectada por los *shocks* originados en el propio país. Este fenómeno posiblemente puede ser explicado por la crisis del sector bancario italiano a mediados de 2016, y su posterior crisis política en mayo 2018. Vale la pena mencionar que, a pesar de que el término constante W no es significativo, lo mantenemos en el modelo para evitar que la varianza condicional decrezca en el tiempo⁵.

Las correlaciones constantes (R) son afectadas únicamente por el primer quiebre encontrado, i.e. coincidiendo con el estallido de la CDSE, mientras que ningún quiebre es encontrado posteriormente o sobre los parámetros relacionados a la estructura dinámica (α y β). Se encuentra que R presenta una pronunciada caída después de la CDSE en todos los casos, indicando altos niveles de fragmentación en los mercados considerados. La caída de R se traduce en niveles inferiores de correlaciones dinámicas, así inferimos que a partir del estallido de la CDSE, los riesgos de fragmentación se han incrementado⁶. Se nota que en particular, la correlación constante Alemania-Francia es tres veces más

⁵Nótese que la suma de los coeficientes GARCH a_n y b_n es menor a uno dada la condición de estacionariedad. Adicionalmente, los valores estimados son cercanos a cero, por lo cual $H_0 : intercepto = 0$ está corroborando la hipótesis de que el parámetro se encuentra en la frontera del espacio. Esto puede traer implicaciones en su distribución bajo la hipótesis nula por lo que el p - *value* asociado puede ser inapropiado. Por esta razón nos abstenemos de interpretar quiebres en W .

⁶También notamos que las correlaciones Francia-Grecia e Italia-Grecia son más bajas que el resto antes de la CDSE, coincidiendo con los resultados de [Candelon et al. \(2022\)](#).

alta que Alemania-Italia, mientras que Alemania-Grecia presenta un signo negativo⁷. Considerando a Francia como un país representativo del núcleo e Italia y Grecia de la periferia (Campos & Macchiarelli, 2016), estos resultados respaldan la hipótesis que los riesgos de fragmentación están asociados a las dinámicas de núcleo-periferia. Más precisamente, Favero (2013) y Candelon et al. (2022) muestran que, luego de la CDSE, las dinámicas conjuntas entre retornos de núcleo y periferia a partir de este momento comienzan a fracturarse dando lugar a co-movimientos discrepantes.

En la Figura 4.2 ilustramos en color negro la correlaciones dinámicas entre país-referencia. Los términos constantes reportados en la Tabla 4.1 son ilustrados en azul. Graficamos también un umbral de 0.7⁸ para comparar los niveles de fragmentación y la posición de las fechas de quiebre encontradas sobre los parámetros de correlación. Los períodos de recortes o *trimming-windows* ($\pi_0 = 0,25$ y $1 - \pi_0 = 0,75$) están sombreados en gris.

Observamos que luego de nuestro primer quiebre (en abril 2010), las correlaciones dinámicas decrecen pronunciadamente en todos los casos, dando evidencia de fragmentación de mercado en los tres países considerados. Se puede notar que, mientras que la correlación Francia-Alemania permanece en niveles superiores al umbral de 0.7, Italia-Alemania y Grecia-Alemania permanecen por debajo⁹. Un marcado declive de las correlaciones Francia-Alemania es encontrado en junio 2016, probablemente causado por la turbulencia de mercado ocasionada por el *Brexit* (Belke et al., 2018). Coincidiendo

⁷Este resultado coincide con Ehrmann & Fratzscher (2017) quienes encuentran una correlación negativa pronunciada entre Alemania y Grecia luego de la CDSE. Los autores relacionan este hallazgo a mecanismos de *flight-to-quality*.

⁸El umbral 0.7 es comúnmente usado para indicar una fuerte grado de correlación. Ver por ejemplo Ratner (2017).

⁹Estos resultados coinciden con Candelon et al. (2022) y Costola & Iacopini (2023).

con el lanzamiento del OMT en septiembre 2012, encontramos que la correlación Italia-Alemania empieza a incrementarse y excede el umbral a mediados de 2015, posiblemente respondiendo al siguiente programa lanzado por el BCE, el PSPP. Posteriormente, altos niveles de fragmentación son inferidos para Italia en mayo 2018 coincidiendo con su crisis política¹⁰. Con respecto a Grecia, por un lado el riesgo de fragmentación decae a partir de octubre 2018, cuando el sentimiento inversor empieza a recuperarse, sin embargo en febrero 2017 el reporte no favorable del FMI posiblemente explica la pronunciada caída en las correlaciones estimadas¹¹.

Coincidiendo con el inicio de la crisis ocasionada por el COVID-2019, se estima una caída en las correlaciones Italia-Alemania y Grecia-Alemania, sin embargo luego se mantienen en niveles superiores al umbral. Estos resultados están alineados con [Costola & Iacopini \(2023\)](#) quienes encuentran que los riesgos de fragmentación se reducen en países de la periferia luego de que el BCE lanzara los programas de compras de activos *Pandemic Emergency Purchase Programme (PEPP)* y *Pandemic Emergency Longer-Term Refinancing Operations (PELTROs)*. Sin embargo, este resultado debe ser cuidadosamente interpretado dado que estos eventos suceden dentro de nuestro período de recorte, por lo que no podemos asegurar la ausencia de quiebres estructurales¹².

¹⁰[Costola & Iacopini \(2023\)](#) también encuentran evidencia de fragmentación durante la crisis política italiana en mayo 2018. Los autores consideran a los países representantes del núcleo a Austria, Bélgica, Finlandia, Francia, Alemania y Países Bajos y de la periferia a Irlanda, Italia, Portugal, España y Grecia.

¹¹Ver historial de eventos relacionados a la crisis de deuda griega en [IMF \(2017\)](#)

¹²Dado el recorte seleccionado $\pi_0 = 0,25$, la detección de posibles quiebres que puedan tomar lugar luego de 2021/01/11 no es posible.

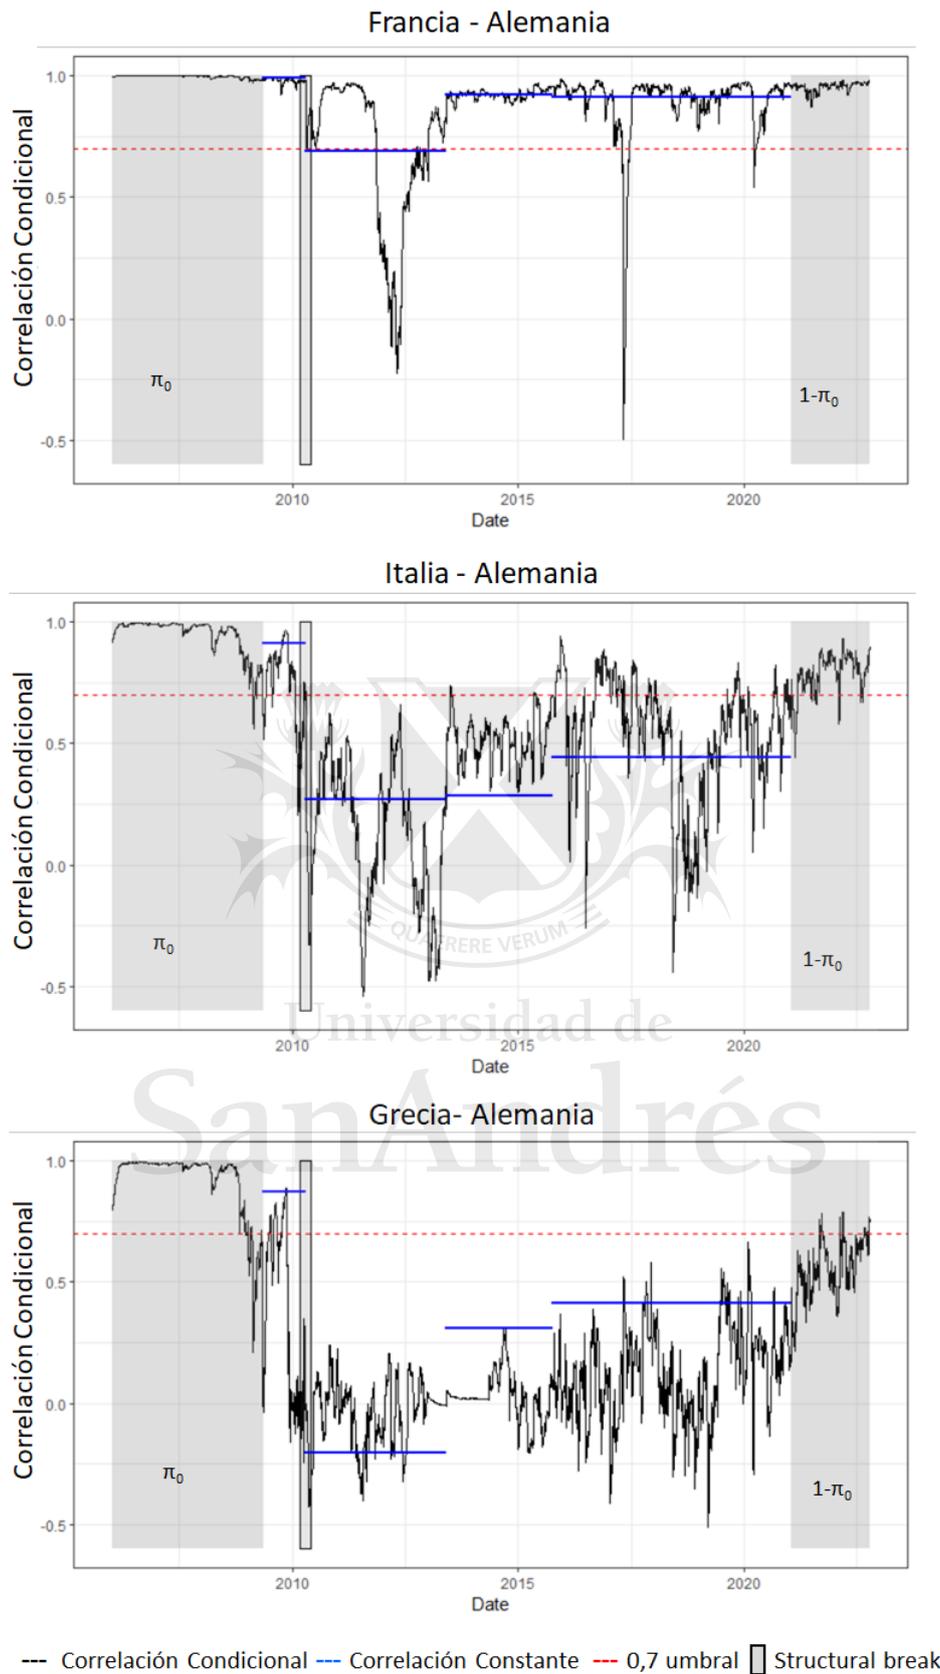


Figura 4.2: Las tres correlaciones dinámicas

Capítulo 5

Chequeo de Robustez

En esta sección, probamos la validación del modelo utilizado analizando los residuos estandarizados por la matriz de covarianzas estimada (ϵ_t^*) dados por $\Omega_t^{-1/2}y_t$ (Ver [Tse, 2000](#)). Adicionalmente, corroboramos los resultados encontrados empleando otra referencia de mercado perfectamente integrado. Para ello, reemplazamos el índice FTSE de bonos alemanes por el índice FTSE de bonos de Estados Unidos como se hace en [Miranda-Agrippino & Rey, 2020](#). Las Tablas y Figuras pertenecientes a esta sección son reportadas en el Apéndice.

En la Figura 7.1 reportamos la función de auto-correlación (ACF) de ϵ_t^* . Inferimos la no-existencia de auto-correlación de los residuos del modelo para un nivel de significancia del 5%. Para corroborar este resultado, realizamos una prueba Breusch-Godfrey ([Godfrey, 1978](#)) que permite la detección de correlación serial entre los errores contemporáneos y el primer rezago, i.e. $\epsilon_t^* = \rho\epsilon_{t-1}^*$. Dado que los p -values son mayores que 0.05 inferimos la no existencia de correlación serial en todos los casos (ver Tabla 7.3) ¹.

Finalmente realizamos la prueba de causalidad de Granger, primero en las seis com-

¹Adicionalmente realizamos la prueba Breusch-Godfrey sobre los retornos (y_t) y no rechazamos la presencia de correlación serial. Como consecuencia, concluimos que al estimar la covarianza estimada con el modelo DCC-GARCH logramos corregir la auto-correlación serial de los retornos (ver Tabla 7.2).

binaciones de retornos cross-seccionales $(y_{t,n}y_{t,m})$ y luego sobre los residuos del modelo $(\epsilon_{t,n}^*\epsilon_{t,m}^*)$. Encontramos que $y_{t,n}$ Granger-causa $y_{t,m}$ para todo $m \neq n$. Sin embargo, no encontramos signos de causalidad de Granger en los residuos estandarizados con la covarianza dinámica estimada.

Con el propósito de corroborar nuestros hallazgos, consideramos el retorno de bonos del Tesoro de Estados Unidos como referencia y realizamos el *TSSA*. Los resultados, ilustrados en la Tabla 7.3, están alineados con los reportados en la sección anterior. Primero, los tres quiebres encontrados en la covarianza de los cuatro activos, i.e. 2010/05/06 (+/-33 días), 2013/06/26 (+/-40 días) y 2015/11/02 (+/-42 días), son cercanos a las posiciones estimadas en la sección anterior y caen dentro de sus respectivos intervalos de confianza. Segundo, luego de la CDSE, las correlaciones constantes estimadas decaen también pronunciadamente. Tercero, el término constante de la correlación Francia-referencia en el cuarto régimen presenta niveles similares al período previo a la CDSE. Por el contrario, Italia-referencia y Francia-referencia permanecen en niveles inferiores. Finalmente, las correlaciones dinámicas presentan evoluciones similares a las reportadas en la sección anterior (ver Figura 7.2).

Capítulo 6

Conclusión

Este trabajo propone medir riesgos de fragmentación de mercado a través del análisis de las correlaciones dinámicas entre un país dado y un mercado perfectamente integrado sujetas a posibles cambios estructurales. Utilizando un modelo DCC-GARCH podemos asociar bajos niveles de correlación dinámica con una baja sincronización entre ambos mercados e inferir mayores riesgos de fragmentación. Aplicando el algoritmo *TSSA* podemos encontrar quiebres estructurales múltiples y posiblemente distintos a lo largo de los parámetros pertenecientes tanto a la estructura de varianza como a la de correlación. De esta manera, evitamos el sesgo en los parámetros estimados de la correlación dinámica producto de heteroscedasticidad condicional o posibles quiebres estructurales en la varianza.

Considerando el período desde abril 2006 a octubre 2022, analizamos riesgos de fragmentación en tres países pertenecientes a la UME, i.e. Francia, Italia y Grecia. Tomando como referencia a Alemania como mercado perfectamente integrado encontramos mayores riesgos de fragmentación a partir de la CDSE en todos los mercados considerados. Más específicamente, coincidiendo con la literatura precedente, encontramos que, la CDSE ha dado lugar a una mayor fragmentación de mercado, que incluso en la actualidad, sigue siendo comparativamente superior a la observada en los primeros años de la EMU.

Posteriormente, detectamos que Grecia comienza a reducir su grado de fragmentación a partir de febrero 2017 cuando el FMI había publicado un reporte favorable en cuanto a la evolución macroeconómica del país. Observamos que el mercado de bonos de Francia presentó un mayor grado de fragmentación a partir de la turbulencia de mercado ocasionada por el Brexit en junio 2016. En cuanto a Italia, su crisis bancaria a mediados del 2016 y su crisis política en mayo 2018 parece haber generado un mayor grado de fragmentación en su mercado de bonos. Mientras que el lanzamiento de programas de compra de bonos por parte del BCE como el *Outright Monetary Transactions* (OMT) y el *Public Sector Purchase Programme* (PSPP) parece estar dar lugar a un menor grado de fragmentación.

En cuanto a los quiebres estructurales, identificamos el primer quiebre el 2010/04/09 momento a partir del cual el término constante de las correlaciones presenta un declive sustancial. Otros quiebres son encontrados más adelante en la estructura de volatilidad, i.e. 2013/05/31 y 2015/10/12. En la prueba de robustez, al reemplazar la referencia por el mercado de Estados Unidos, encontramos fechas de quiebre y dinámicas de fragmentación coincidentes.

Nuestros resultados empíricos están alineados con investigaciones previas sobre fragmentación en el mercado de bonos. Sin embargo, nuestro método se diferencia en tres aspectos claves. Primero, mientras que la mayoría de los estudios capturan la interacción de un mercado con los factores globales a través de coeficientes de medias, nuestro procedimiento permite que el grado de dependencia cross-seccional varíe en el tiempo, incluso dentro de los regímenes estimados, como en [Costola & Iacopini \(2023\)](#). Segundo, nuestra metodología permite la existencia de quiebres estructurales que afectan a los parámetros del modelo, donde las fechas de quiebre son encontradas endógenamente por el modelo. Finalmente, nuestro modelo reconcilia tres hechos estilizados propios de los retornos de mercado i) retornos de media cero ii) volatilidad dependiente del tiempo, (iii) correlaciones dinámicas.

Futuras aplicaciones podrían ser realizadas con el objetivo de analizar riesgos de fragmentación para un grupo de países más amplio. En un futuro cercano, sería interesante verificar la existencia de quiebres estructurales a partir del 2021/01/11, período en el cual la detección de quiebres no es posible debido a nuestra ventana de recorte. Adicionalmente, alternativas al umbral de 0.7 podrían ser propuestas para determinar niveles de riesgo de fragmentación. Por ejemplo, probabilidades de transición asociadas a altas/bajas correlaciones dinámicas podría ser una posibilidad.



Capítulo 7

Apéndice

7.1. Las funciones *score* del modelo DCC-GARCH

Bajo el supuesto de normalidad las funciones de verosimilitud condicionales de la observación y ($1 \times N$) en el momento t es maximizada a través de dos pasos. Primero, los parámetros de varianza (θ). Luego, los parámetros de correlación (ϕ) tomando $\bar{\theta}$ como dado. Las funciones de verosimilitud pueden ser descompuestas como:

$$l_t(\theta, \phi) = l_t^V(\theta) + l_t^C(\bar{\theta}, \phi),$$

donde

$$l_t^V(\theta) = -\frac{1}{2}(N \ln 2\pi + \ln |V_t|^2 + y_t' V_t^{-2} y_t),$$

y

$$l_t^C(\bar{\theta}, \phi) = -\frac{1}{2}(\ln |R_t| + \epsilon_t' R_t^{-1} \epsilon_t + \epsilon_t' \epsilon_t).$$

El vector *score* para la parte de volatilidad $\frac{\partial l_t^V}{\partial \theta}$ es de largo N . Luego, para el activo n tenemos que

$$\frac{\partial l_t^V}{\partial \theta_n} = \frac{1}{2v_{n,t}} \frac{\partial v_{n,t}}{\partial \theta_n} \left(\frac{y_{n,t}^2}{v_{n,t}} - 1 \right),$$

donde

$$\frac{\partial v_{n,t}}{\partial \theta_n} = (1, y_{n,t-1}^2, v_{n,t-1}) + b_n \frac{\partial v_{n,t-1}}{\theta_n},$$

y $v_{n,t}$ y b_n corresponden al elemento n de la diagonal de la matriz de varianzas V_t^2 y el parámetro B respectivamente

El vector *score* para la parte de correlación $\frac{\partial l_t^C}{\partial \phi}$ es de dimensión $(N^* + 2)$, donde $N^* = N(N - 1)/2$. Así,

$$\frac{\partial l_t^C}{\partial \phi} = -\frac{1}{2} \frac{\partial \text{vecl}(R_t)'}{\partial \phi} \text{vecl}[R_t^{-1}(I_N - \epsilon_t \epsilon_t' R_t^{-1})],$$

y

$$\frac{\partial \text{vecl}(R_t)'}{\partial \phi} = \frac{\partial \text{vecl}(R_t)}{\partial \text{vech}(Q_t)'} \frac{\partial \text{vech}(Q_t)}{\partial \phi}.$$

Nótese que el operador *vec* apila a la matriz en un vector, *vech* y *vecl* apilan solo el triángulo inferior de la matriz simétrica, aunque *vecl* excluye la diagonal. Adicionalmente, D_N es la matriz de duplicación y $D_{N,-}^+$ su inversa generalizada, tal que $\text{vec}(R) = D_N \text{vecl}(R)$ y $\text{vecl}(R) = D_{N,-}^+ \text{vec}(R)$ (ver [Hafner & Herwartz, 2008](#)).

Por simplicidad, $Q_t^* = \text{diag}(Q_t^{-1/2})$, luego

$$\frac{\partial \text{vecl}(R_t)}{\partial \text{vech}(Q_t)'} = D_{N,-}^+(Q_t^* \otimes Q_t^*) D_N + D_{N,-}^+(Q_t Q_t^* \otimes I_N + I_N \otimes Q_t Q_t^*) D_N \frac{\partial \text{vech}(Q_t^*)}{\partial \text{vech}(Q_t)'},$$

donde \otimes es el producto Kronecker y

$$\frac{\partial \text{vech}(Q_t^*)}{\partial \text{vech}(Q_t)'} = -\frac{1}{2} \text{diag}(\text{vech}(Q_t^{-3/2})).$$

Finalmente, $\frac{\partial \text{vech}(Q_t)}{\partial \phi'}$ puede ser dividida en tres parámetros de correlación de la siguiente manera

$$\frac{\partial \text{vech}(Q_t)}{\partial R'} = \frac{1 - \alpha - \beta}{1 - \beta} I_d,$$

$$\frac{\partial \text{vech}(Q_t)}{\partial \alpha} = -\text{vech}(R) + \text{vech}(\epsilon_{t-1}\epsilon'_{t-1}) + \beta \frac{\partial \text{vech}(Q_{t-1})}{\partial \alpha},$$

$$\frac{\partial \text{vech}(Q_t)}{\partial \beta} = -\text{vech}(R) + \text{vech}(Q_{t-1}) + \beta \frac{\partial \text{vech}(Q_{t-1})}{\partial \beta},$$

donde I_d es una matriz índice cuyos elementos toman el valor de uno cuando la derivada correspondiente no es nula, y de otra manera cero¹.

7.2. Notación formal del algoritmo de segmentación de tres pasos

El *TSSA* procede formalmente de la siguiente manera:

1. Replicar L veces el proceso de *repartición* para cada parámetro $\psi \subseteq \Psi$:
 - a) Crear L variables aleatorias ordenadas, $\pi_{\psi}^l \in \mathbb{R}^M$, distribuidas en el intervalo $[\tau_{\psi,j-1}\pi_0, \tau_{\psi,j-1}(1 - \pi_0)]$ donde $\tau_{\psi,0} = T$, $m \in (0, 1)$, $M = m\tau_{\psi,j-1}$, $\pi_0 \in (0, 1/2)$, $l \in [1, \dots, L]$ y L es suficientemente alto.
 - b) Computar $SupLM_{\psi,j}^l$ para todo $l \in [1, \dots, L]$:
 - 1) Si $SupLM_{\psi,j}^l > qcrit$ para todo $l \in [1, \dots, P]$ pero $\frac{P}{L} < \varphi$, la detección es terminada.
 - 2) Si $SupLM_{\psi,j}^l > qcrit$ todo $l \in [1, \dots, P]$ pero $\frac{P}{L} \geq \varphi$, recuperar las fechas de quiebre estimadas $\widehat{\pi}_{\psi,j}^l$ y computar $\tau_{\psi,j}^l = T - \widehat{\pi}_{\psi,j}^l T$. Repetir pasos 1.a y 1.b hasta que la detección sea terminada o hasta que $\tau_{\psi,j}^l \pi_0$ sea cercano a T .

¹Por ejemplo para $N=3$, $I_d = \begin{Bmatrix} 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \end{Bmatrix}$.

2. Determinar si las posiciones encontradas en el paso previo (si lo hubiera) son significativamente distintas entre los diferentes parámetros.

a) Tomar la secuencia $(\widehat{\pi}_{\psi,j}^l)_{l \in P}$ para todo par (ψ, j) para el cual $\frac{P}{L} > \phi$. Ordenar las secuencias y computar los intervalos de confianza al 95 % ($CI_{\psi,j}$).

b) Para cada $CI_{\psi,j}$ coleccionar los pares $(\psi, j) \subseteq (1, \dots, s) \times (1, \dots, \lambda_\psi)$. Luego, tomar todas las posibles combinaciones $2, \dots, \lambda_{total}$ de pares para distintos ψ 's.

Si para cierta combinación:

1) Los intervalos de confianza se superponen, tomar los pares correspondientes y crear el grupo \mathcal{G}_g .

2) Los intervalos de confianza no se superponen, crear los grupos \mathcal{G}_g conformados por cada par individualmente.

c) Computar $\widehat{\pi}_g = \underset{(\psi,j) \in \mathcal{G}_g}{Avg} (CI_{\psi,j})$ para todos los grupos \mathcal{G}_g definidos en el paso previo.

3. Estimar la varianza de parámetros $\bar{\theta} = [\theta_1, \theta_2, \dots, \theta_{G_\theta}]$ entre las G_θ fechas distintas encontradas en el paso 1 y 2 para los parámetros de correlación (ϕ) utilizando la función de máxima verosimilitud $l_t^C(\bar{\theta}, \phi)$.

7.3. Tablas y Figuras complementarias

Tabla 7.1: Lista de índices seleccionados

País	Índice FTSE
Francia	SBFFL Index
Italia	SBITL Index
Grecia	SBGRL Index
Alemania	SBDML Index
Estados Unidos	SBWGU Index

Fuente: Bloomberg.

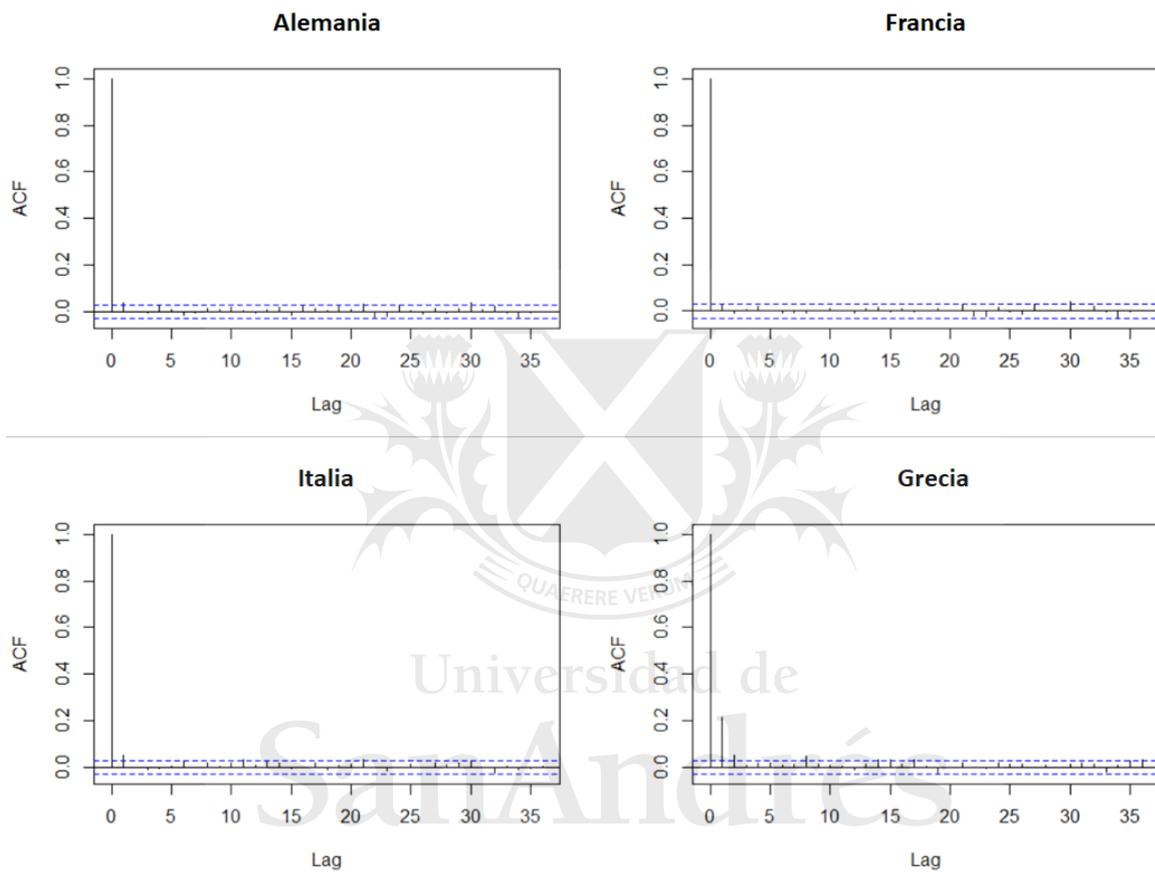
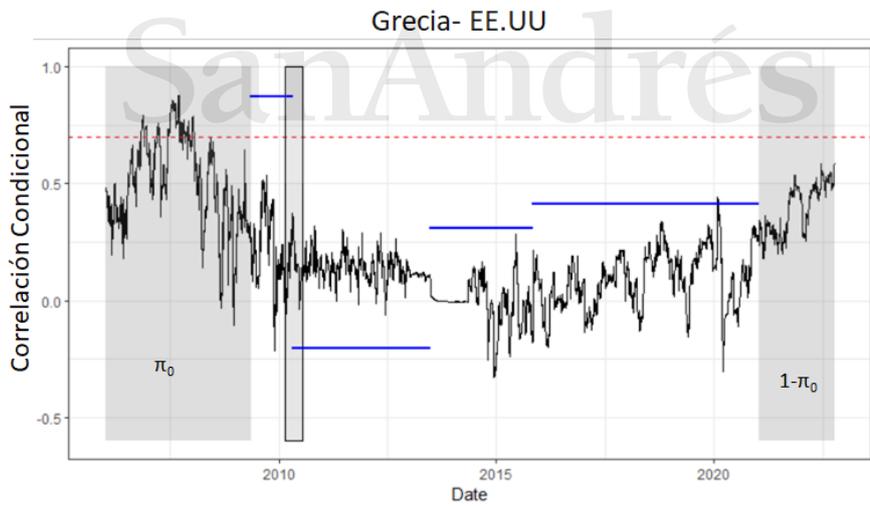
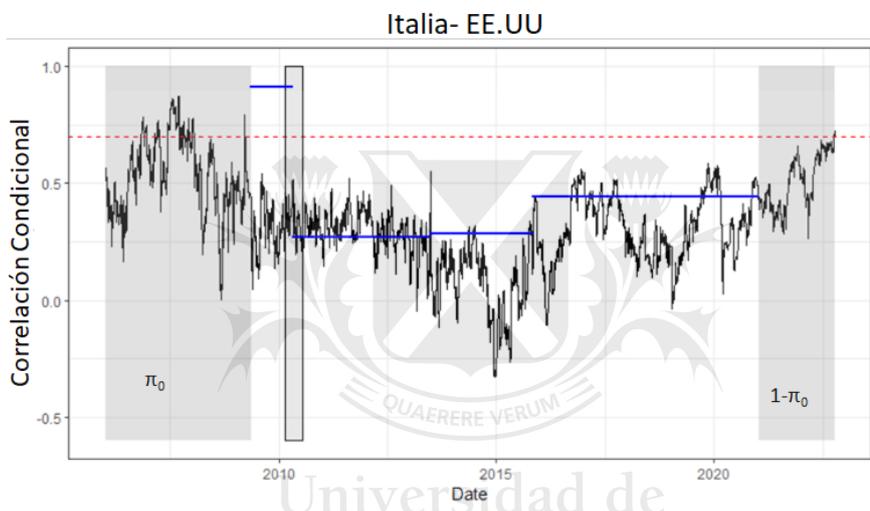
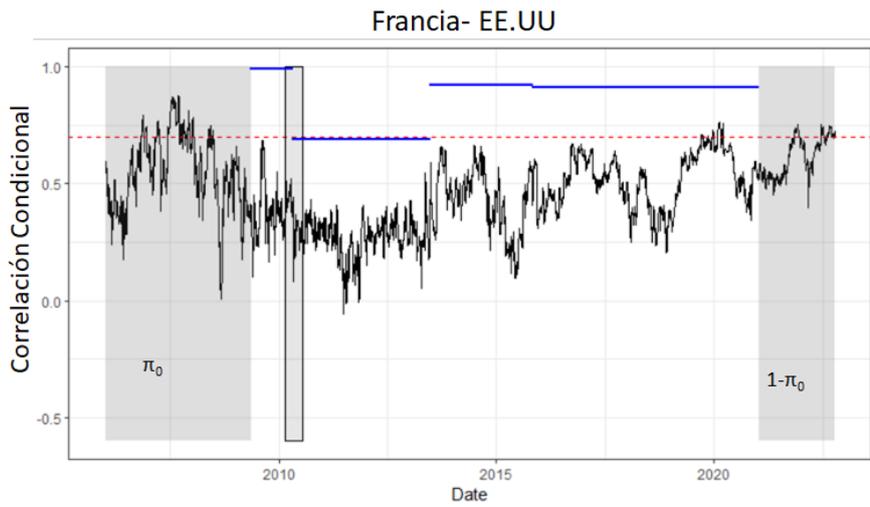


Figura 7.1: Chequeo de Robustez: Auto-correlación de los residuos (ϵ^*)



-- Correlación Condicional --- Correlación Constante - - - 0,7 umbral █ Structural break ak

Figura 7.2: Chequeo de Robustez: Las tres correlaciones dinámicas

Tabla 7.2: Chequeo de Robustez - Prueba de auto-correlación y causalidad de Granger

	Alemania	Francia	Italia	Grecia
Retornos de bonos soberanos (y_t)				
Breusch-Godfrey	0.4580	0.8835	0.4809	0.1188
Causalidad Granger				
Francia	0.0000***	-	-	-
Italia	0.0001***	0.0052**	-	-
Grecia	0.0026**	0.0001***	0.01141*	-
Residuos estandarizados no-correlacionados ($\epsilon_t^* = \Omega_t^{-1/2} y_t$)				
Breusch-Godfrey	0.0000****	0.0830*	0.0004***	0.0000****
Causalidad Granger				
Francia	0.3207	-	-	-
Italia	0.3372	0.7399	-	-
Grecia	0.3003	0.4866	0.2460	-

Notas: p-values: * $\leq 0,05$, ** $\leq 0,01$, *** $\leq 0,001$ y **** $\leq 0,0001$.

Tabla 7.3: Chequeo de Robustez - Parámetros estimados para los cuatro regímenes encontrados

	[1] [2006/01/04- 2010/05/06]	[2] [2010/05/06- 2013/06/26]	[3] [2013/06/26- 2015/11/02]	[4] [2015/11/02- 2022/10/12]
Parámetros de Varianza				
$W_{Francia}$	0.0000	0.0000	0.0000	0.0000
$A_{Francia}$	0.0362***	0.0803	0.0263	0.0491
$B_{Francia}$	0.9605****	0.8966**	0.9705****	0.9463****
W_{Italia}	0.0000	0.0000	0.0000	0.0000
A_{Italia}	0.0628	0.1690*	0.0522	0.1508
B_{Italia}	0.9222****	0.8413****	0.9022****	0.8376****
W_{Grecia}	0.0000	0.0000	0.0000	0.0000
A_{Grecia}	0.0987	0.4772	1.0000*	0.1738**
B_{Grecia}	0.9133****	0.6682****	0.5804****	0.8320****
$W_{EE.UU}$	0.0000	0.0000	0.0000*	0.0000
$A_{EE.UU}$	0.0267	0.0350****	0.0336****	0.0714***
$B_{EE.UU}$	0.9704	0.9609****	0.9645****	0.9172****
Parámetros de Correlación				
α	0.0570****	0.0384****	0.0382****	0.0268****
β	0.9421****	0.8663****	0.9413****	0.9655****
$R_{Francia,EE.UU}$	0.5144	0.2715 [-47 %]	0.4282 [+57 %]	0.5418 [+26 %]
$R_{Italia,EE.UU}$	0.4835	0.2940 [-39 %]	0.0673 [-77 %]	0.3586 [+432 %]
$R_{Grecia,EE.UU}$	0.4385	0.1352 [-69 %]	-0.0114 [-108 %]	0.1678 [-1565 %]
$R_{Francia,Italia}$	0.8945	0.1532 [-82 %]	0.5059 [+230 %]	0.5828 [+15 %]
$R_{Francia,Grecia}$	0.7862	-0.0405 [-105 %]	0.0253 [-162 %]	0.2285 [+802 %]
$R_{Italia,Grecia}$	0.9074	0.2537 [-72 %]	0.2891 [+13 %]	0.4474 [+54 %]

Notas: p-values: * $\leq 0,05$, ** $\leq 0,01$, *** $\leq 0,001$ y **** $\leq 0,0001$.

Bibliografía

- Adams, Z., Füss, R., & Glück, T. (2017). Are correlations constant? empirical and theoretical results on popular correlation models in finance. *Journal of Banking & Finance*, 84, 9–24. <https://doi.org/10.1016/j.jbankfin.2017.07.003>
- Aielli, G. P. (2013). Dynamic conditional correlation: on properties and estimation. *Journal of Business & Economic Statistics*, 31(3), 282–299.
- Al-Eyd, A. & Berkmen, S. P. (2015). Fragmentation, the monetary transmission mechanism, and monetary policy in the euro area. *The Mechanics of a Strong Euro Area: IMF Policy Analysis*, 75.
- Al-Eyd, M. A. J. & Berkmen, P. (2013). *Fragmentation and monetary policy in the euro area*. International Monetary Fund.
- Andrade, P., Breckenfelder, J., De Fiore, F., Karadi, P., & Tristani, O. (2016). The ECB's asset purchase programme: an early assessment. *ECB working paper*.
- Andreou, E. & Ghysels, E. (2003). Tests for breaks in the conditional co-movements of asset returns. *Statistica Sinica*, 1045–1073.
- Andrews, D. W. (1993). Tests for parameter instability and structural change with unknown change point. *Econometrica: Journal of the Econometric Society*, 821–856. <https://doi.org/10.2307/2951764>

- Andrews, D. W. (2003). Tests for parameter instability and structural change with unknown change point: A corrigendum. *Econometrica*, 395–397. <https://www.jstor.org/stable/3082056>
- Andrews, D. W. & Ploberger, W. (1994). Optimal tests when a nuisance parameter is present only under the alternative. *Econometrica: Journal of the Econometric Society*, 1383–1414. <https://doi.org//10.2307/2951753>
- Angelini, P., Grande, G., & Panetta, F. (2014). The negative feedback loop between banks and sovereigns. *Bank of Italy Occasional Paper*, (213).
- Angeloni, I. & Ehrmann, M. (2003). Monetary policy transmission in the euro area: any changes after EMU? Available at SSRN 457307.
- Baele, L., Ferrando, A., Hördahl, P., Krylova, E., & Monnet, C. (2004). Measuring financial integration in the euro area. Technical report, ECB occasional paper.
- Bai, J. & Perron, P. (1998). Estimating and testing linear models with multiple structural changes. *Econometrica*, 47–78. <https://doi.org//10.2307/2998540>
- Bauwens, L., Laurent, S., & Rombouts, J. V. (2006). Multivariate GARCH models: a survey. *Journal of applied econometrics*, 21(1), 79–109.
- Belke, A., Dubova, I., & Osowski, T. (2018). Policy uncertainty and international financial markets: the case of Brexit. *Applied Economics*, 50(34-35), 3752–3770.
- Bernoth, K., Dietz, S., Ider, G., & Lastra, R. (2022). The ECB’s Transmission Protection Instrument: a legal economic analysis. *Monetary Dialogue Papers September 2022*.
- Campos, N. F. & Macchiarelli, C. (2016). Core and periphery in the european monetary union: Bayoumi and eichengreen 25 years later. *Economics Letters*, 147, 127–130.

- Candelon, B., Luisi, A., & Roccazzella, F. (2022). Fragmentation in the european monetary union: Is it really over? *Journal of International Money and Finance*, 122, 102545.
- Costola, M. & Iacopini, M. (2023). Measuring sovereign bond fragmentation in the eurozone. *Finance Research Letters*, 51, 103354.
- De Grauwe, P. & Ji, Y. (2012). Mispricing of sovereign risk and macroeconomic stability in the eurozone. *JCMS: Journal of Common Market Studies*, 50(6), 866–880.
- De Grauwe, P. & Ji, Y. (2013). Self-fulfilling crises in the eurozone: An empirical test. *Journal of International Money and finance*, 34, 15–36.
- De Santis, R. A. (2019). Redenomination risk. *Journal of Money, Credit and Banking*, 51(8), 2173–2206.
- ECB (2022). (2022, July 21) The Transmission Protection Instrument [Press release]. www.ecb.europa.eu/press/pr/date/2022/html/ecb.pr220721~973e6e7273.en.html
- Ehrmann, M. & Fratzscher, M. (2017). Euro area government bonds—fragmentation and contagion during the sovereign debt crisis. *Journal of International Money and Finance*, 70, 26–44.
- Engle, R. (2002). Dynamic conditional correlation: A simple class of multivariate generalized autoregressive conditional heteroskedasticity models. *Journal of Business & Economic Statistics*, 20(3), 339–350. <https://doi.org/10.1198/073500102288618487>
- Engle, R. F. & Kroner, K. F. (1995). Multivariate simultaneous generalized ARCH. *Econometric theory*, 11(1), 122–150. <https://www.jstor.org/stable/3532933>

- Estrada, F., Tol, R. S., & Gay-García, C. (2015). The persistence of shocks in GDP and the estimation of the potential economic costs of climate change. *Environmental Modelling & Software*, 69, 155–165. <https://doi.org/10.1016/j.envsoft.2015.03.010>
- Favero, C. A. (2013). Modelling and forecasting government bond spreads in the euro area: a GVAR model. *Journal of Econometrics*, 177(2), 343–356.
- Forbes & Rigobon, R. (2002). No contagion, only interdependence: Measuring stock market comovements. *Journal of Finance*, 57(5), 2223–2261. <https://doi.org/10.1111/0022-1082.00494>
- Garcia-de Andoain, C., Hoffmann, P., & Manganelli, S. (2014). Fragmentation in the euro overnight unsecured money market. *Economics Letters*, 125(2), 298–302.
- Godfrey, L. G. (1978). Testing for higher order serial correlation in regression equations when the regressors include lagged dependent variables. *Econometrica: Journal of the Econometric Society*, 1303–1310.
- Hafner, C. M. & Herwartz, H. (2008). Analytical quasi maximum likelihood inference in multivariate volatility models. *Metrika*, 67(2), 219–239. <https://doi.org/10.1007/s00184-007-0130-y>
- Hansen, B. E. & Seo, B. (2002). Testing for two-regime threshold cointegration in vector error-correction models. *Journal of econometrics*, 110(2), 293–318.
- Hillebrand, E. (2005). Neglecting parameter changes in GARCH models. *Journal of Econometrics*, 129(1-2), 121–138. <https://doi.org/10.1016/j.jeconom.2004.09.005>
- Horvath, R., Kotlebova, J., & Siranova, M. (2018). Interest rate pass-through in the

- euro area: Financial fragmentation, balance sheet policies and negative rates. *Journal of Financial Stability*, 36, 12–21.
- IMF (2017). (2017, february 7) Greece: Ex-Post Evaluation of Exceptional Access Under the 2012 Extended Arrangement-Press Release; Staff Report; and Statement by the Executive Director for Greece.
- Mehmet, S., Ekrem, A. Y., & Gokcen, O. (2014). Cross sectional dependence and cointegration analysis among the GDP-Foreign direct investment and aggregate credits: evidence from selected developing countries. *Asian economic and financial review*, 4(11), 1485–1501.
- Miranda-Agrippino, S. & Rey, H. (2020). Us monetary policy and the global financial cycle. *The Review of Economic Studies*, 87(6), 2754–2776.
- Mugrabi, F. (2023). Detecting and dating possibly distinct structural breaks in the covariance structure of financial assets. Unpublished manuscript. *LIDAM Discussion Paper*, 45.
- Ng, L. (1991). Tests of the CAPM with time-varying covariances: A multivariate GARCH approach. *The Journal of Finance*, 46(4), 1507–1521.
- Oka, T. & Perron, P. (2018). Testing for common breaks in a multiple equations system. *Journal of Econometrics*, 204(1), 66–85. <https://doi.org/10.1016>
- Perron, P. et al. (2006). Dealing with structural breaks. *Palgrave handbook of econometrics*, 1(2), 278–352.
- Ratner, B. (2017). *Statistical and machine-learning data mining:: Techniques for better predictive modeling and analysis of big data*. CRC Press.

Sapir, A. (2018). High public debt in euro-area countries: comparing Belgium and Italy. Technical report, Bruegel Policy Contribution.

Tse, Y. K. (2000). A test for constant correlations in a multivariate garch model. *Journal of econometrics*, 98(1), 107–127. [https://doi.org//10.1016/S0304-4076\(99\)00080-9](https://doi.org//10.1016/S0304-4076(99)00080-9)

Zaghini, A. (2016). Fragmentation and heterogeneity in the euro-area corporate bond market: Back to normal? *Journal of Financial Stability*, 23, 51–61.



Universidad de
San Andrés