



Universidade de Vigo

Máster Universitario en Economía

Universidade da Coruña

Universidade de Santiago de Compostela

Universidade de Vigo

Trabajo Fin de Máster

**Interdependencia bancaria
y transmisión del riesgo
soberano: Evidencia de
Estados Unidos, Europa y
Reino Unido**

Christian Jorge Carreiro

Dirigido por:

Ana Iglesias Casal

Carmen López Andión

Julio 2024

Trabajo de Fin de Máster presentado en la Facultad de Ciencias Económicas y Empresariales de la Universidad de Santiago de Compostela para la obtención del Máster en Economía

Resumen

El objetivo de este trabajo de fin de máster es el análisis de la interdependencia de los sectores bancarios de Europa, Estados Unidos y Reino Unido para el periodo 2019-2024 desde una perspectiva de transmisión del riesgo financiero y el análisis de la transmisión del riesgo soberano de cada área hacia su sector bancario. Para lograr este objetivo, se utiliza dos tipos de metodología, la primera consistente en la estimación de modelos VAR-BEKK-X y VAR-DCC-X ambos con efecto asimétrico y distribución t-Student, mientras que la segunda es el conocido enfoque de la conectividad propuesto por Diebold & Yilmaz. Los resultados muestran la gran dependencia entre la banca europea e inglesa manifestado a través de su alta correlación, mientras que la banca estadounidense y las restantes han mantenido una correlación más baja y variable, asimismo, se hallan efectos spillover entre los tres sectores bancarios, aunque no se ha podido determinar el sentido de la transmisión. También se han hallado dichos efectos, aunque débiles, desde la deuda soberana a sus respectivos sectores bancarios.

Palabras clave: Finanzas, Riesgo, Spillovers, Volatilidad.

Abstract

The objective of this master's final project is to analyze the interdependence among the european, north american and english banking over the period 2019-2024 from a financial risk transmission prospect and the analysis of sovereign risk transmission towards it's own bank system. In order to achive this goal, two methodological approaches have been used, the first one relies on the estimation of VAR-BEKK-X and VAR-DCC-X both with leverage effect and t-Student distribution, while the second one is the well-known connectedness approach proposed by Diebold & Yilmaz. The results shed light to the fact that the european and english banking are highly dependent as shown by their high correlation, whilst the north american banking and both of the former kept a lower and more variable correlation, in addition, spillover effects have been found among the three bank systems, although it has not been possible to determine their direction. Also these effects show up from sovereigns to it's own banking although these are weaker.

Keywords: Finance, Risk, Spillovers, Volatility.

Índice

1. INTRODUCCIÓN.....	1
2. REVISIÓN DE LA LITERATURA.....	2
2.1. El sector bancario y su relación con la deuda soberana.	2
2.2. Análisis de la transmisión del riesgo y spillovers de volatilidad.	5
3. METODOLOGÍA Y DATOS.....	8
3.1. El modelo BEKK.....	9
3.2. El modelo de correlación condicional dinámica (DCC)	10
3.3. El enfoque de la conectividad.....	12
3.4. Datos.....	14
4. RESULTADOS	17
5. CONCLUSIONES	29
BIBLIOGRAFÍA	31

Índice de Gráficos

Gráfico 1. Evolución de la exposición soberana de las diferentes áreas seleccionadas (% sobre activos totales).....	2
Gráfico 2. Composición de las carteras de deuda soberana de los países europeos según origen en el 4ºT de 2023.	3
Gráfico 3. Composición por vencimientos de las carteras de renta fija soberana de los países europeos.	4
Gráfico 4. Evolución temporal de los índices bancarios utilizados.....	15
Gráfico 5. Evolución temporal de los índices de renta fija utilizados.....	16
Gráfico 6. Correlaciones condicionales de los modelos estimados.....	22
Gráfico 7. Varianzas condicionales de los modelos estimados.....	22
Gráfico 8. Evolución del índice TCI.	25
Gráfico 9. Red de conectividad.	26
Gráfico 10. Índices netos de spillovers	26
Gráfico 11. Índices netos de spillovers por pares.....	27

Índice de Tablas

Tabla 1. Principales estadísticos de las series utilizadas	15
Tabla 2. Modelos BEKK estimados.....	18
Tabla 3. Modelos DCC estimados.....	19
Tabla 4. P-Valores de los contrastes de autocorrelación y efecto ARCH sobre las innovaciones estandarizadas y sus cuadrados.	20
Tabla 5. Contrastes para los efectos spillover	21
Tabla 6. Tabla de conectividad.	24

1. Introducción.

El sector bancario juega un papel trascendental en la dinámica económica tanto en un panorama nacional como internacional y, debido a ello, es realmente útil y necesario comprender los problemas, riesgos y puntos débiles de este sector para así poder evitar dichos fenómenos lo cuales pueden acabar provocando crisis financieras profundas y persistentes como la ocurrida en 2008. En este sentido, posee especial relevancia la caracterización y análisis de la interconexión de los diversos sistemas bancarios del mundo ya que, la comprensión y entendimiento de estas relaciones transfronterizas en un sector tan clave como este, puede ayudar notablemente a establecer marcos regulatorios que eviten un contagio a nivel internacional (Z. Chen et al., 2022; Choudhry & Jayasekera, 2014; Zhao et al., 2022).

Por otro lado, es importante entender como otros mercados, activos y sectores afectan a la banca través de la exposición que a estos mantienen, en este sentido, son diversos los trabajos que indagan la relación y los efectos de las carteras de deuda soberana de la banca (Altavilla et al., 2017; Angeloni & B.Wolff, 2012; Baziki et al., 2023; Bottero et al., 2020), así como los determinantes de dicha exposición (Altavilla et al., 2017; Ongena et al., 2019), mostrando la influencia que esta exposición tiene en el perfil de riesgo de las entidades e incluso como afecta a su capacidad de crédito, llegando a afectar de esta manera a la economía real.


Es por todo lo anterior que, en este trabajo, a la vista de la relevancia de la cuestión, se tratará de analizar e indagar a cerca de la relación entre 3 sectores bancarios relevantes: el estadounidense, europeo y el de Reino Unido. El periodo de estudio que se utilizará será desde enero de 2019 hasta mayo de 2024, pudiendo así capturar fenómenos como la pandemia del COVID-19, el estallido de la guerra de Ucrania y la quiebra del Silicon Valley Bank. El objetivo que se perseguirá es doble, por un lado, se analizará la interconexión de los anteriores sectores bancarios, cuestión interesante para el caso de Reino Unido tras el Brexit, a través de la modelización de las correlaciones, la conectividad entre ellos y el estudio de efectos transmisores de riesgo (o genéricamente por su término en inglés *spillovers*), mientras que, por otro lado, se estudiará si se induce la incertidumbre en los mercados de renta fija soberana de las áreas anteriormente mencionadas a la incertidumbre de los sectores bancarios de las áreas anteriormente mencionadas, de esta forma se podrá obtener evidencia de la relación con esta que han tenido los diferentes sectores bancarios durante los últimos turbulentos años.

La estructura del trabajo se organiza de la siguiente manera: en el **apartado 2** se realiza una revisión de la literatura, subdividiéndola en una primera revisión de la evolución reciente de las tenencias de deuda soberana de la banca de las áreas anteriores y, la exposición de la literatura que evidencia los efectos de la relación entre la banca y la deuda soberana, mientras que en la segunda parte de este apartado se trata la literatura que analiza la transmisión del riesgo y las técnicas más ampliamente utilizadas; en el **apartado 3** se realizará una exposición metodológica, indicando y explicando las características más relevantes de la metodología empleada para lograr el objetivo propuesto, asimismo también se indicarán los datos utilizados; en el **apartado 4** se presentarán los resultados mientras que en último lugar en el **apartado 5** se indicarán las conclusiones obtenidas.

2. Revisión de la literatura

2.1. El sector bancario y su relación con la deuda soberana.

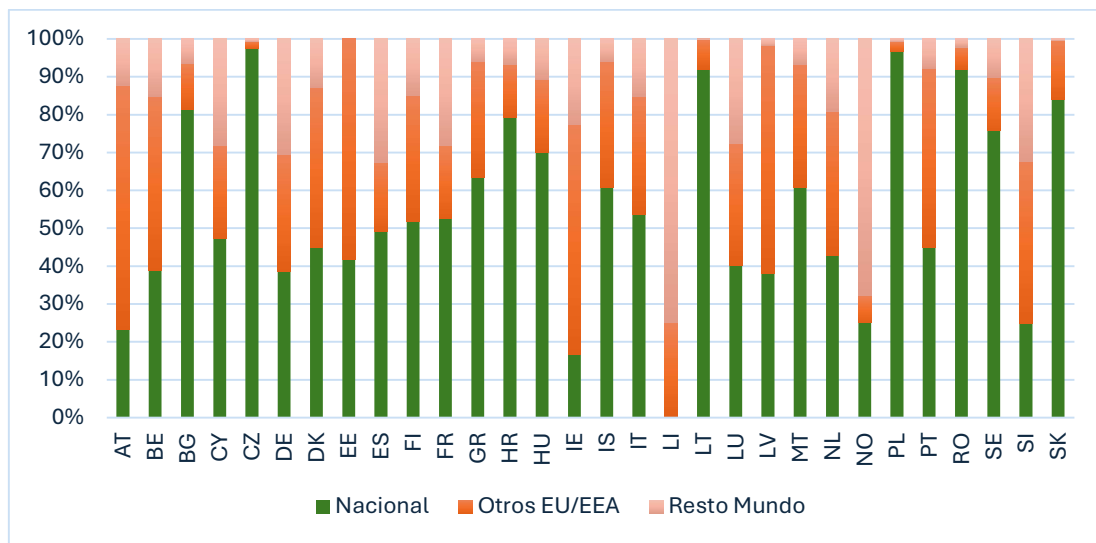
Para una correcta comprensión de la relación del sector bancario con la deuda soberana, conviene en un primer momento visualizar como ha sido la evolución de la exposición a esta en los últimos años.



Fuente: Elaboración propia con datos de la EBA, BoE y FED.

Gráfico 1. Evolución de la exposición soberana de las diferentes áreas seleccionadas (% sobre activos totales).

Como se puede ver en el **Gráfico 1**, aunque los periodos para los que hay disponibles datos difieren, la evolución de la exposición de las tres áreas seleccionadas ha sido diferente. Respecto a Europa, desde el primer semestre del año 2020 ha ido reduciendo su posición neta soberana hasta el primer semestre de 2022, momento a partir del cual ha ido aumentando su exposición hasta niveles muy similares a los del 2020 (12%) a finales del año 2023 (11.89%). Por otro lado, para la banca inglesa, esta tendencia se ha mantenido a la baja hasta marzo de 2024, donde ha alcanzado una exposición del 7.8% frente al 10.38% al inicio del periodo de análisis. Ahora bien, en el caso de la banca estadounidense, su exposición ha seguido un camino totalmente diferente para el mismo periodo que Europa y Reino Unido, donde ha tenido una tendencia notablemente creciente desde mediados de 2020 hasta principios de 2022, donde llegó a un nivel de la exposición de en torno al 21%, momento a partir del cual ha ido moderando dicha exposición hasta 2024, aunque su nivel de 17.88% sigue siendo superior al del inicio con un 15.79%.




Fuente: Elaboración propia con datos de la EBA.

Gráfico 2. Composición de las carteras de deuda soberana de los países europeos según origen en el 4ºT de 2023.

Atendiendo al **Gráfico 2** puede comprobarse que, en términos generales, para la mayoría de los países la predominancia que tienen los títulos nacionales frente a los otros orígenes, así, para países como República Checa y Portugal, la exposición nacional soberana de su sector bancario llega al 97% para el último trimestre de 2023, en contraposición con países como Lituania, donde su sector bancario carece prácticamente de exposición soberana nacional, pues solo representa un 0.2% del total. En términos medios, el sector bancario europeo muestra una exposición nacional notable, situándose de media en torno a un 49% del total en el mencionado trimestre de 2023.

Por otro lado, en el **Gráfico 3** se presenta la composición de dichas carteras según vencimiento ya que este factor determinará aproximadamente la duración de estas y, por tanto, como de sensibles son a las variaciones de los tipos de interés de mercado. Se aprecia como en términos generales las carteras presentan una dominancia de plazos cortos (menos de 1 año) y medios (de 1 a 5 años) suponiendo en torno a un 52% en términos totales. En el caso particular como el de Eslovaquia o República Checa, esta proporción es de en torno a un 40% y 35% respectivamente, poniendo de manifiesto que estas carteras de renta fija son más sensibles ante cambios en los tipos de interés de mercado.



Fuente: Elaboración propia con datos de la EBA.

Gráfico 3. Composición por vencimientos de las carteras de renta fija soberana de los países europeos.

Caso contrario es el de Islandia, donde su exposición hasta 5 años supone cerca del 95% de la cartera de renta fija de su sector bancario, o el caso de Lituania, donde su sector bancario mantiene una posición similar en dicho plazo de vencimiento. Ahora que se ha expuesto la relevancia que tiene la deuda soberana en el balance del sector bancario es relevante ver la evidencia obtenida de estudios previos sobre lo que esta exposición puede suponer, los riesgos de ello y los motivos que hacen que estos se manifiesten.

En Altavilla et al. (2017), donde estudian los determinantes de la exposición soberana de la banca europea durante 2007 a 2015 y, como esta afecta a su capacidad de crédito, exponen algunos motivos, al menos los más relevantes, por los que la banca mantiene renta fija soberana. El primero es lo que se denomina *persuasión moral*, según esta hipótesis, los bancos de propiedad pública o que han sido rescatados son más propensos a mantener una exposición superior a dichos títulos¹, sobre todo los del país en el que se ubican, que los bancos que no cumplen estas características.

De hecho, Ongena et al. (2019) investigan acerca de esta *persuasión moral* durante el periodo de crisis de la deuda soberana europea, concluyendo que existe una “coordinación” notable entre los bancos nacionales y la deuda soberana especialmente en momentos de estrés fiscal, jugando los primeros un papel estabilizador reduciendo dicho estrés fiscal estabilizando los rendimientos y primas, actuando así como “compradores de último recurso” cuando para los demás actores del mercado no es atractivo. Asimismo, indican que el efecto es mucho más notable en los bancos de propiedad estatal siendo indiferente a las tenencias iniciales de dichos activos, su patrimonio neto o incluso el flujo de depósitos que estos reciben.

Por otro lado Altavilla et al. (2017), también indican que los bancos poco capitalizados, son más propensos a la exposición de deuda soberana de alto riesgo, en una especie de apuesta por obtener grandes rentabilidades. De su investigación concluyen que por un lado, en los países que sufrieron más esta crisis soberana, la banca de propiedad pública y poco capitalizada incrementó sus tenencias de deuda soberana nacional e indican también que, las exposiciones soberanas de los bancos de los países más afectados

¹ Sobre todo, en épocas de estrés en los mercados de deuda soberana

mostraron significatividad en la transmisión del estrés soberano al crédito corporativo, incluso afectado a otros mercados, de forma que, los bancos de estos países en crisis soberana tendieron a reducir el crédito incluso en los países que no presentaban problemas con su deuda soberana.

En este sentido autores como Angeloni & B. Wolff (2012), investigan si la banca se ve afectada en su desempeño en los mercados de capitales por sus tenencias de deuda soberana de países vulnerables durante la crisis (como Italia, Grecia o España) , estos, centran su trabajo en el periodo de la crisis financiera del 2008 y años posteriores, más allá de las conclusiones relativas al contexto, concluyen que la localización del banco afecta a la conexión entre su riesgo y el riesgo soberano así como la credibilidad del gobierno y la viabilidad de la economía y sistema financiero.

Otros trabajos como el de Baziki et al. (2023) indagan acerca de cómo afecta la composición de las carteras de deuda soberana al perfil de riesgo de los bancos. Centrándose en la banca europea para el periodo 2008-2018 hallan que aquellos bancos localizados en países con mayor riesgo soberano presentan mayor riesgo, asimismo, muestran que los bancos con mayores tenencias de deuda soberana de su país no presentan más riesgo que los que poseen menor proporción de esta.

Efecto relevante es también lo que se denomina nexo soberano-bancario, esto es, la transmisión del riesgo soberano hacia la banca que se da vía deterioro de las notables carteras de renta fija soberana (y no soberana) que los bancos mantienen, impactando las variaciones del valor de mercado de dichos títulos en el valor de mercado de los bancos, ya sea a través de su cuenta de resultados, patrimonio o valor económico (Ibarz et al., 2022), fenómeno el cual es de especial relevancia en escenarios de crisis. En esta línea, trabajos como el de Caporin et al. (2019) investigan la evidencia de dicho fenómeno utilizando las permutas de incumplimiento crediticio (CDS) soberanos de Dinamarca y dos bancos daneses durante su quiebra en los años de la crisis financiera los cuales no fueron rescatados por el gobierno de dicho país y, de su análisis concluyen que dicha decisión por parte del gobierno danés permitió evitar este fenómeno y alejar a dicho país de los riesgos a los que dicho bancos estaban expuestos.

Otros efectos documentados en la literatura son los inducidos a la oferta de crédito, en este sentido, como ya se evidenció en Altavilla et al. (2017), Bottero et al. (2020) investigan la propagación de las tensiones financieras durante la crisis financiera hacia la economía italiana a través del deterioro de las tenencias de títulos por parte de los bancos. Los autores concluyen que, durante la agitación de los mercados soberanos a consecuencia del rescate a Grecia, se produjo una contracción de la oferta de crédito por parte de instituciones financieras más expuestas a deuda soberana de países afectados², produciendo así una caída en la inversión y empleo, sobre todo en pequeñas empresas más dependientes de la financiación bancaria.

2.2. Análisis de la transmisión del riesgo y spillovers de volatilidad.

El estudio de la transmisión de la volatilidad, principalmente aplicado a activos y mercados financieros, es de patente importancia dada la relevancia que poseen la

² Grecia, Irlanda, Portugal y España

caracterización y la comprensión del riesgo e incertidumbre inherente a estos ya que, esta incertidumbre o riesgo, es de crucial relevancia en la toma de decisiones de inversión, abarcando desde la formación de carteras que minimicen lo máximo posible la exposición a dicho riesgo, control y medición de las pérdidas potenciales de una posición (obtención de medidas como el *Value at Risk* (VaR) o el *Expected Shortfall* (ES)), o incluso en el proceso de valoración de activos financieros en los cuales el riesgo toma parte activa, como pueden ser productos derivados como las opciones.

Teniendo en cuenta todo lo anterior, es trascendental el análisis de la dependencia de este riesgo entre distintos activos y mercados de cara a poder realizar las anteriores labores. En el caso de, por ejemplo, autores como Sadorsky (2012), este estudia y modeliza la existencia de spillovers de volatilidad entre los rendimientos del petróleo y los rendimientos de las acciones de empresas de energías limpias y empresas tecnológicas, para luego utilizar la información de dicha modelización para la construcción de ponderaciones óptimas de carteras formadas por pares de los activos anteriores y obtener ratios de cobertura. Para llevar a cabo su trabajo utiliza diversos modelos GARCH multivariantes (BEKK, CCC, DCC), utilizando un VAR (1) para la media condicional y una especificación VARMA-GARCH (1,1) para las varianzas. De su análisis concluye que las correlaciones dinámicas entre las empresas de energías limpias y las tecnológicas son más altas que las de las primeras y el petróleo, asimismo, indica que es posible construir una cartera con acciones de empresas de energías limpias y futuros del petróleo y estos pueden utilizarse como cobertura en la inversión en dichas empresas.

Chen et al. (2020) investigan la existencia de spillovers de volatilidad y las correlaciones dinámicas entre el *Mainlan New Energy Index*, *Rare earth Industry index* y el precio del petróleo Brent. Utilizando un VAR-BEKK asimétrico y un DCC, arrojan luz sobre el hecho de que el Rare earth market ha sido el nexo de transferencia de riesgo entre los mercados de nuevas energías y el de petróleo en China, asimismo, muestran la alta interdependencia entre el *Rare earth market* y el mercado de energías nuevas. Song et al. (2022) estudian efectos spillover entre la generación de energía solar y eólica para lo cual utilizan un VAR para la media condicional, un VARMA-GARCH para las varianzas y la aproximación de Diebold & Yilmaz (2012), basada en la descomposición generalizada de la varianza la cual se utiliza para construir los índices de conectividad o de spillovers propuestos por estos y, en base a ellos, construir ratios de cobertura y ponderaciones óptimas. De los resultados de su trabajo concluyen la existencia de efectos spillover con tendencia y ciclo dependientes de la nueva capacidad instalada de ambas energías, al mismo tiempo que muestran la dinámica negativa en las correlaciones de estas.

Lin et al. (2014) tratan de hallar efectos spillover entre el mercado de petróleo y los mercados de acciones de Ghana y Nigeria utilizando un DCC con especificación VARMA-GARCH y utilizando los resultados para la construcción de ratios de cobertura y ponderaciones óptimas. Por otro lado, Mensi et al. (2014) investigan dichos efectos de transmisión de volatilidad entre mercados energéticos y de materias primas utilizando un VAR-BEKK y un VAR-DCC, encontrando efectos bidireccionales en el mercado de cebada para los mercados de petróleo y gasolina. Un caso algo diferente es el de Chen et al. (2023), el cual encuentra una débil correlación entre el *Baltic Dry Index*, el mineral de hierro y el petróleo Brent utilizando una Cópula dinámica, aunque si halla efectos spillover entre los tres mercados utilizando un VAR-BEKK-X.

Asimismo, trabajos en este ámbito también enfocados en el análisis y comprensión de esta transmisión de la volatilidad en el sector bancario, son el de Apostolakis et al. (2022) los cuales utilizan un modelo TVP-VAR y un DCC para a través del enfoque de la conectividad y la modelización de las correlaciones dinámicas, hallar los sectores bancarios transmisores y receptores de efectos spillover de los países del G7. De su estudio concluye que dicho efecto es significativo entre los mercados bancarios estudiados, sobre todo en los mercados europeos, aunque resaltan la heterogeneidad en la respuesta a shocks comunes de los diferentes integrantes del mencionado continente.

Otro ejemplo de esto es Z. Chen et al. (2022), los cuales muestran el mayor efecto transmisor en las rentabilidades que en la volatilidad que hay entre las nuevas finanzas digitales y los bancos tradicionales, resaltando que los bancos de propiedad estatal son los que más presentan estos efectos en volatilidad, al mismo tiempo que destaca el carácter de exportador neto de volatilidad que tienen las finanzas por internet. Choudhry & Jayasekera (2014) estudian la transmisión de la volatilidad en el sector bancario europeo durante la crisis financiera del 2008, a través de un GJR-GARCH bivariante llegan a la conclusión de que existió un incremento en los spillovers en volatilidad y rendimiento entre las principales economías europeas y las más pequeñas, principalmente de Alemania, Reino Unido y EE.UU. hacia las pequeñas economías (España, Italia y Portugal por ejemplo), sin embargo esto no se ha dado en el sentido inverso, obteniendo así evidencia de efecto asimétrico.

Ejemplo interesante es también el de Zhao et al. (2022), los cuales estudian efectos spillover en los sectores bancarios para los países del *Belt and Road*. Utilizando un modelo VAR-BEKK-GARCH concluyen el papel trascendental que posee China como exportador y receptor de la mayor parte de los efectos spillover. Otros estudios encuentran, haciendo uso de un modelo DCC, regresiones cuantil y utilizando la medida del VaR, la mayor respuesta del sector bancario a nivel global ante la crisis financiera del 2008 frente a la situación del COVID-19 y la reciente guerra de Rusia y Ucrania (Batten et al., 2023).

Para finalizar, se muestran algunos hallazgos y evidencia sobre la transmisión del riesgo entre el mercado de deuda soberana (e incluso renta fija más en general) y el sector bancario. En esta línea, trabajos como el de Keddad & Schalck (2020), autores que, utilizando un *Markov Switching-Time-variant parameter model* (MS-TVP) para la mayoría de la banca europea, hallan la considerable influencia que las permutas de incumplimiento crediticio (CDS) soberanas tienen en la dinámica que hace entrar a las CDS de los bancos en el régimen de crisis. Conclusión similar alcanzan Gomez-Puig et al. (2019), donde, entre otras técnicas, utilizan la aproximación propuesta por Diebold & Yilmaz (2012), hallando evidencia de una fuerte interconexión y co-movimientos entre los indicadores de riesgo de la banca local y los indicadores de riesgo soberanos europeos.

En definitiva, el estudio, comprensión y medición del riesgo y de cómo este se transmite entre los diversos mercados, activos, países y sectores, es de especial utilidad y relevancia no solo para la toma de decisiones de inversión como ya se había indicado en un primer momento, sino que en casos tan particulares como el sector bancario, puede incluso servir para guiar las decisiones de política económica que a estos afecte ya no directamente, sino indirectamente a través de la exposición y su relación con otros países o sectores y, de esta forma, tomar decisiones de política que comprometan lo menos posible la estabilidad financiera.

3. Metodología y datos

Para poder comprender las diferentes técnicas empleadas conviene, en un primer momento, definir las cuestiones más básicas y elementales sobre las que los posteriores métodos se sostienen. Considérense $i = \{1, 2, \dots, N\}$ activos, y sus respectivos precios $P = \{P_1, P_2, \dots, P_n\}$ en diferentes momentos del tiempo $t = \{1, 2, \dots, T\}$, donde se puede definir su rentabilidad en tiempo continuo como las primeras diferencias logarítmicas de estos precios, es decir:

$$r_t = \ln \left(\frac{P_t}{P_{t-1}} \right) \times 100$$

De esta forma, según la frecuencia a la que se tomen los datos de los precios de los activos, se tendrán rentabilidades diarias, semanales, etc.... las cuales se podrán asumir como procesos estocásticos y descomponer en dos elementos fundamentales tal como se indica a continuación:

$$r_t = \mu_t + \varepsilon_t \quad [1]$$

Dónde μ_t es lo que se denomina media condicional al conjunto de información Ω_{t-1} , mientras que, ε_t es el componente estocástico del proceso generador de datos de las rentabilidades. Desde un enfoque tradicional, se asume que dicho componente posee su primer momento (su media) nulo, esto es $E[\varepsilon_t] = 0$ y su segundo momento (su varianza) finito y constante, esto es $E[\varepsilon_t^2] = \sigma_\varepsilon^2$. Sin embargo, de la ecuación [1], se deduce que la varianza de la rentabilidad está dada por la varianza de ε_t ya que $E[(r_t - \mu_t)^2] = E[\varepsilon_t^2] = \sigma_\varepsilon^2$ y por tanto, asumir que la dispersión de las rentabilidades de los activos, en definitiva, su volatilidad es constante a lo largo del tiempo es, cuanto menos, restrictivo en un sentido amplio (M.H. Pesaran, 2015).

Es por eso por lo que, para flexibilizar esta asunción se representa el proceso estocástico [1], haciendo que el componente estocástico sea el resultado del producto de una variable ruido blanco normal, con media 0 y desviación típica 1, y una variable que recoge la evolución temporal de la anterior mencionada volatilidad, esto es:

$$\varepsilon_t = z_t \sqrt{h_t}, z_t \sim i. i. d N(0,1) \rightarrow r_t = \mu_t + z_t \sqrt{h_t} \quad [2]$$

Donde h_t es lo que se denomina varianza condicional del proceso al conjunto de información Ω_{t-1} . Notese que ahora, la varianza del proceso es $E[(r_t - \mu_t)^2] = E[\varepsilon_t^2 | \Omega_{t-1}] = E[(z_t \sqrt{h_t})^2] = h_t$, y, por tanto, es dinámica en el tiempo.

Todo lo anterior, es aplicable al caso multivariante, que será el de interés para este trabajo. Tomando [2] y adaptándolo dicho caso, podemos representarlo como:

$$\mathcal{R}_t = M_t + H_t^{1/2} Z_t \quad [3]$$

Donde, \mathcal{R}_t es un vector columna de rentabilidades de dimensión $N \times 1$; M_t es la matriz de la media condicional, que será un modelo $VAR(p)$, cuyo orden p se seleccionará de acuerdo al criterio de información de Schwarz; H_t es una matriz definida positiva de covarianzas de dimensión $N \times N$ y, Z_t es un vector columna de perturbaciones aleatorias normales independientes e idénticamente distribuidas con igual dimensión a \mathcal{R}_t , y, cuya media es un vector de ceros y su matriz de covarianzas es I_N . De esta forma, tanto la media como la varianza condicional pueden modelizarse, y hacer inferencia en ambas.

3.1. El modelo BEKK

Este modelo, propuesto por Engle & Kroner (1995), modeliza directamente la matriz de covarianzas anteriormente indicada. Esta especificación permite asegurar que dicha matriz sea positiva definida al estar basada en formas cuadráticas, a diferencia del modelo $VECH$ de Bollerslev et al. (1988) utilizado hasta entonces, incluso en su versión diagonal. El modelo tiene la siguiente especificación:

$$H_t = C_0 C_0' + \sum_{i=1}^m A_i (\varepsilon_{t-i} \varepsilon_{t-i}') A_i' + \sum_{j=1}^s B_j H_{t-j} B_j' + \sum_{k=1}^n D_k (\varepsilon_{t-k} \varepsilon_{t-k}' | \varepsilon_{t-k} < 0) D_k'$$

Donde C_0 es una matriz triangular inferior, y A_i , B_j y D_k son matrices $N \times N$ dimensionales de parámetros, donde la última matriz recoge el efecto asimétrico o apalancamiento. El problema que tiene este modelo es, por un lado, la cantidad de parámetros a estimar que es de $N^2(m + s + n) + N(N + 1)/2$ y, como se puede comprobar, crece rápidamente incluyendo más series, o más retardos en el proceso (cuando m , s y n son más grandes), además de que las correlaciones no se modelizan directamente, obteniéndose como $\rho_{i,t} = h_{ij,t} / \sqrt{h_{ii,t} h_{jj,t}}$, donde h_{ij} es la covarianza entre la serie i y la serie j . Por otro lado, los parámetros no tienen interpretación directa, ya que la especificación en un BEKK (1,1) bivalente (ignorando el efecto asimétrico por simplicidad) para la varianza condicional de la primera serie en concreto viene dada por:

$$h_{11,t} = c_{11}^2 + a_{11}^2 \varepsilon_{1,t-1}^2 + b_{11}^2 h_{11,t-1} + a_{12}^2 \varepsilon_{2,t-1}^2 + b_{12}^2 h_{22,t-1} + 2a_{11} a_{12} \varepsilon_{1,t-1} \varepsilon_{2,t-1} + 2b_{11} b_{12} h_{12,t-1}$$

De esta forma, la varianza condicional queda no solo en función de los shocks y valores pasados de dicha varianza propios de la serie, sino que también es función de los productos cruzados de los shocks de las series y los valores pasados de las varianzas de estas. Esto permite estudiar efectos spillover procedentes de otras series, haciendo inferencia en los parámetros correspondientes que, por ejemplo, en la especificación anterior, sería equivalente a contrastar la significatividad de los parámetros b_{12} y a_{12} y, en caso de incluir asimetría d_{12} , en términos generales, los coeficientes fuera de la diagonal principal de las matrices mencionadas son los que recogen estos efectos spillover, de forma que los coeficientes con subíndice ij indican la transmisión de la serie j hacia la serie i .

Asimismo, en este modelo se pueden incluir variables exógenas siguiendo a autores como Y. Chen et al. (2020, 2023), Zheng et al. (2022), añadiendo a la expresión anterior $EE'X$, donde E es una matriz triangular inferior como C_0 , y X es un vector de las

observaciones de la mencionada variable exógena³, permitiendo así, a través del contraste de los parámetros de la matriz E , comprobar si dicha variable exógena induce volatilidad a las series modelizadas, incluso si esta relación no es directa.

3.2. El modelo de correlación condicional dinámica (DCC)

Propuesto por R. Engle (2002), este modelo trata de ir un paso más allá en la modelización de la matriz de covarianzas, partiendo de la idea propuesta por Bollerslev, (1990) en el que propone un modelo de correlación condicional constante, el cual supone que las correlaciones entre las series son constantes, en el modelo DCC, se trata de modelizar la matriz de correlaciones de la siguiente manera:

$$\begin{aligned}
 H_t &= D_t^{1/2} R_t D_t^{1/2} \\
 R_t &= \text{diag}(Q_t)^{-1/2} Q_t \text{diag}(Q_t)^{-1/2} \\
 Q_t &= (1 - \alpha - \beta) \bar{Q} + \alpha z_{t-1} z'_{t-1} + \beta Q_{t-1}
 \end{aligned}$$

Donde D_t es una matriz diagonal de dimensión $N \times N$ compuesta por las varianzas condicionales y R_t es la matriz de correlaciones condicionales de las innovaciones estandarizadas, Q_t es una matriz definida positiva de igual dimensión que D_t y, \bar{Q} es la matriz de correlaciones incondicionales o marginales de las innovaciones estandarizadas.

En definitiva, este modelo no solo recoge y caracteriza la heterocedasticidad condicional de los rendimientos o series financieras, sino que también permite modelizar las correlaciones logrando así recoger su evolución temporal. Nótese que, el esquema que siguen las correlaciones es en cierto sentido restrictivo, ya que ambos parámetros que deben cumplir $0 < \alpha + \beta < 1$, son los mismos para cualquier par de series. A día de hoy no existe una solución sólida fuertemente asentada para atajar este problema, una solución es la propuesta por Billio et al. (2006), los cuales proponen un DCC flexible (FDCC) donde los parámetros de la ecuación de las correlaciones se especifican en forma de bloque, permitiendo diferentes parámetros entre diversos grupos de series.

Respecto a las varianzas condicionales, la proposición inicial de R. Engle (2002) consistía en que la estimación se llevase a cabo en dos etapas⁴, modelizando en un primer momento la varianza condicional de cada serie, y luego en base a sus innovaciones estandarizadas obtener la estimación de la matriz de correlaciones. Sin embargo, esto no permite recoger ni modelizar efectos spillover entre las varianzas de las series y, como respuesta a ello, han surgido principalmente dos especificaciones de las varianzas que sí permite recoger estos efectos, las cuales son:

- *Varianzas Spillover y Koutmos*

En esta especificación las varianzas condicionales quedan en función de una constante los q retardos de las innovaciones al cuadrado de las series y p retardos de su varianza condicional. Esta especificación tiene principalmente dos variantes, la primera es una versión simple, mientras que la segunda fue propuesta por Koutmos (1996) y siguen una

³ Que en este caso será el cuadrado de los rendimientos logarítmicos de los índices de renta fija.

⁴ Este procedimiento logra obtener estimadores consistentes pero no eficientes (M. H. Pesaran, 2015).

estructura EGARCH. Las especificaciones son las siguientes para el caso de un solo retardo temporal:

$$\begin{aligned} \text{Spillover} &\rightarrow h_{ii,t} = c_{ii} + \sum_{j=1}^J a_{ij} \varepsilon_{t-1}^2 + \beta_i h_{ii,t-1} \\ \text{Koutmos} &\rightarrow \log(h_{ii,t}) = c_{ii} + \sum_{j=1}^J a_{ij} \left(\frac{|\varepsilon_{j,t-1}|}{\sqrt{h_{ii,t-1}}} + d_j \frac{\varepsilon_{j,t-1}}{\sqrt{h_{ii,t-1}}} \right) + \beta_i \log(h_{ii,t-1}) \end{aligned}$$

De esta forma se recogen efectos spillover pero solo a través de los shocks de cada serie y no de los valores pasados de sus varianzas condicionales

- *Varianzas VARMA*

Siguiendo a autores como Lin et al. (2014) y Sadorsky (2012), los cuales utilizan esta especificación en sus modelos GARCH multivariantes, esta formulación propuesta por Ling & McAleer (2003), permite definir las varianzas de cada serie en función de los retardos de las innovaciones propias y de otras series, así como los retardos de las varianzas condicionales de estas, es decir, para el caso de un solo retardo temporal:

$$h_{ii,t} = c_{ii} + \sum_{j=1}^J a_{ij} \varepsilon_{t-1}^2 + \sum_{j=1}^J \beta_{ij} h_{ij,t-1}$$

De esta forma, es posible realizar inferencia sobre los parámetros que acompañan a los retardos de las innovaciones y las varianzas de las restantes series para comprobar si existen efectos spillover entre estas. Asimismo, hay que mencionar que, aunque no se ha dispuesto explícitamente, estas especificaciones también pueden incluir un término de asimetría tal como un GJR-GARCH y variables exógenas.

Respecto a la estimación de estos modelos, se lleva a cabo por máxima verosimilitud, donde dicha función de verosimilitud viene dada por las siguientes expresiones (Bauwens et al., 2006):

$$\begin{aligned} \mathcal{L}_T(\zeta) &= \sum_{t=1}^T \ln(f(\mathcal{R}_t | \zeta, \Omega_{t-1})) \\ f(\mathcal{R}_t | \zeta, \Omega_{t-1}) &= |H_t|^{-1/2} g(H_t^{-1/2}(\mathcal{R}_t - M_t) | \eta) \end{aligned}$$

Donde, $g(\bullet)$ es la densidad condicional de las innovaciones estandarizadas y ζ es un vector de parámetros que puede representarse como la unión de dos conjuntos disjuntos $\zeta = (\theta, \eta)$, donde el primer elemento es el vector de parámetros de las medias y varianzas condicionales, mientras que el segundo es un vector de parámetros que caracteriza la función de densidad condicional. En el caso de una densidad Gaussiana, este vector es nulo, y el único a estimar es $\theta = \zeta$ y el log-verosimilitud toma la siguiente expresión:

$$\mathcal{L}_T(\theta) = -\frac{TN}{2} \ln(2\pi) - \frac{1}{2} \sum_{t=1}^T \ln |H_t| - \frac{1}{2} \sum_{t=1}^T z_t' z_t$$

Asimismo, la suposición de una función de densidad Normal para las innovaciones puede ser irreal, y estar poco avalado por la evidencia empírica dado el exceso de curtosis que suelen mostrar los rendimientos financieros y que se traduce en distribuciones leptocúrticas caracterizadas por tener colas más densas que la distribución normal (Bauwens et al., 2006; Tsay, 2005). Es por esto por lo que, con el fin de atajar este problema puede asumirse que la densidad de dichas innovaciones es tipo t-Student ya que esta permite capturar mejor esta característica de los rendimientos financieros. En dicho

caso, la función de densidad $g(\bullet)$ y el log-verosimilitud viene dada por las siguientes expresiones⁵:

$$g(z_t | \theta, \nu) = \frac{\Gamma(\frac{\nu+N}{2})}{\Gamma(\frac{\nu}{2})[\pi(\nu-2)]^{\frac{N}{2}}} \left[1 + \frac{z_t' z_t}{\nu-2} \right]^{-\frac{(N+\nu)}{2}}$$

$$\mathcal{L}_T(\zeta) = T \ln \left(\frac{\Gamma(\frac{\nu+N}{2})}{\Gamma(\frac{\nu}{2})} \right) - \frac{TN}{2} \ln(\pi(\nu-2)) - \frac{1}{2} \sum_{t=1}^T \ln |H_t| - \frac{N+\nu}{2} \sum_{t=1}^T \ln \left(1 + \frac{z_t' z_t}{\nu-2} \right)$$

Donde $\Gamma(\bullet)$ es la función gamma y ν son los grados de libertad de la mencionada distribución, los cuales han de estimarse y para los cuales se supone $2 < \nu < \infty$, con lo cual $\eta = \nu$, y, por tanto, $z_t \sim i. i. d St(0, I_N, \nu)$.

3.3. El enfoque de la conectividad

Esta metodología, difiere respecto a la anterior principalmente en que modeliza y caracteriza la evolución temporal de la volatilidad de las rentabilidades desde un enfoque notablemente diferente a los modelos GARCH multivariantes. Desde la perspectiva de esta metodología, Diebold & Yilmaz (2012) proponen construir índices de conectividad basados en la descomposición de la varianza de los conocidos modelos de vectores autorregresivos (VAR).

Partiendo de la expresión de un modelo $VAR(p)$ en su forma reducida y, aplicando la representación de Wold de este como un vector de medias móviles de orden infinito $VMA(\infty)$:

$$VAR(p) \rightarrow \mathcal{R}_t = \sum_{i=1}^p \Phi_i \mathcal{R}_{t-i} + \varepsilon_t$$

$$VMA(\infty) \rightarrow \mathcal{R}_t = \sum_{i=1}^{\infty} A_i \varepsilon_{t-i}$$

Donde $\varepsilon_t \sim (0, \Sigma)$ es un vector de perturbaciones independientes e idénticamente distribuidas; A_i es una matriz de dimensión $N \times N$ de parámetros, obtenida mediante sustitución recursiva tal que $A_i = \Phi_1 A_{i-1} + \Phi_2 A_{i-2} \dots + \Phi_p A_{i-p}$. Gracias a la representación de los modelos VAR como un VMA es posible obtener las funciones de respuesta a los impulsos (IRF) y la descomposición de la varianza del error de la predicción (FEVD), la cual permite analizar que fracción de la varianza del error de la predicción H periodos a futuro que de la serie i es debido a los shocks de las restantes series.

Para realizar este análisis normalmente es necesario que las innovaciones sean ortogonales, un método ampliamente utilizado para lograr dicha ortogonalización es la descomposición de Cholesky. Sin embargo, esta descomposición es sensible a la ordenación de las variables, es decir, dependiendo de cómo se ordenen en el sistema, las IRF y la FEVD pueden variar notablemente entre ordenaciones. Aunque podría solventarse este problema utilizando una matriz estructural para obtener innovaciones ortogonales, es una tarea relativamente laboriosa identificar esta matriz, además de que para cada sistema que se plantee esta matriz sería diferente y requeriría volver a

⁵ Nótese que $\varepsilon_t' H_t^{-1} \varepsilon_t = z_t' z_t$

identificarla, es decir, la matriz estructural de un modelo VAR de un conjunto de series es diferente de la de otros modelos VAR utilizando otros conjuntos de series.

Por tanto, para llevar a cabo dicha descomposición sin el problema de la ordenación y los problemas extra de identificación de la matriz estructural, Diebold & Yilmaz (2012) proponen utilizar la descomposición generalizada de la varianza del error de la predicción (GEFVD) propuesta por H.H. Pesaran & Shin (1998) y Koop et al. (1996) la cual computa las innovaciones no ortogonalizadas de tal forma⁶ que dicha descomposición no se ve alterada a la ordenación de las variables en el sistema. Su expresión viene dada por:

$$\Psi_{ij}(H) = \frac{\sigma_{jj}^{-1} \sum_{h=0}^{H-1} (e_i' A_h \Sigma e_j)^2}{\sum_{h=0}^{H-1} e_i' A_h \Sigma A_h' e_i}$$

Donde Σ es la matriz de covarianzas del vector de perturbaciones, σ_{jj} es la desviación típica de la ecuación j , e_i es un vector de selección con 1's en la posición i y 0's en las demás. Dado que esta descomposición no se basa en innovaciones ortogonales, la suma de las contribuciones a la varianza del error de la predicción⁷ no suman necesariamente 1, es decir $\sum_{j=1}^N \Psi_{ij}(H) \neq 1$. Es por ello que, para utilizar esta descomposición para el cálculo de los índices que se indicarán posteriormente, Diebold & Yilmaz (2012) normalizan cada elemento del anterior sumatorio dividiéndolo por dicho sumatorio, esto es:

$$\tilde{\Psi}_{ij}(H) = \frac{\Psi_{ij}(H)}{\sum_{j=1}^N \Psi_{ij}(H)}$$

Nótese que ahora, $\sum_{j=1}^N \tilde{\Psi}_{ij}(H) = 1$ y asimismo $\sum_{i,j=1}^N \tilde{\Psi}_{ij}(H) = N$. Con toda esta información se presentan a continuación los diferentes índices a calcular

- *Índice total de spillovers*

$$S(H) = \frac{\sum_{i,j=1}^N \tilde{\Psi}_{ij}(H)}{N} \times 100$$

Utilizando las contribuciones a la varianza del error de la predicción de cada serie, se calcula el anterior índice. Este mide la contribución de los spillovers de los shocks de volatilidad de todas las series a la varianza del error de la predicción. Puede interpretarse como una medida del grado de conexión de las series.

- *Índice direccional de spillovers*

$$S_{i \leftarrow j}(H) = \frac{\sum_{j=1}^N \tilde{\Psi}_{ij}(H)}{N} \times 100$$

⁶ Ver M.H. Pesaran (2015) para el desarrollo matemático y mayores detalles.

⁷ La suma de los elementos fila de la tabla de la descomposición de la varianza.

$$S_{j \leftarrow i}(H) = \frac{\sum_{\substack{j=1 \\ i \neq j}}^N \tilde{\Psi}_{ji}(H)}{N} \times 100$$

Este índice permite analizar la dirección de los spillovers de volatilidad de cada serie, así, la primera expresión indica los spillovers recibidos por parte de la serie i procedentes de las series j . Asimismo, la segunda expresión mide los spillovers que la serie i envía a todas las demás series j .

- *Índice neto de spillovers*

$$S_i(H) = S_{j \leftarrow i}(H) - S_{i \leftarrow j}(H)$$

Este índice es el resultado de restar a los spillovers transmitidos desde la serie i hacia todas las demás los que esta recibe de todas ellas y, por tanto, permite caracterizar si dicha serie recibe más o menos volatilidad de lo que transmite a las demás.

- *Índice neto por pares de spillovers*

$$S_{ij}(H) = \left(\frac{\tilde{\Psi}_{ji}(H) - \tilde{\Psi}_{ij}(H)}{N} \right) \times 100$$

Este índice, a diferencia del anterior, es el resultado de restar los spillovers recibidos por la serie i procedentes de la serie j , de esta forma es posible entender la naturaleza de la conexión entre las series desde un punto de vista más detallado entre pares de estas, para así discernir en que momentos una induce volatilidad a la otra y viceversa.

3.4. Datos

Para llevar a cabo este trabajo, para calcular las rentabilidades tal como se han descrito, como variables representativas de los sectores bancarios de Europa, Reino Unido y Estados Unidos, se utilizarán el Euro STOXX Banks (SX7E), el FTSE 350 Banks (FTNM301010) y el NASDAQ Banks (IXBK) respectivamente. Por otro lado, como variables representativas de la renta fija de cada área, se utilizará el ICE BofA 7-10Y German Bond Index para Europa (MERG4DO), ICE U.S Treasury 7-10Y Bond Index (IDCT7RT) para el caso de Estados Unidos y, Refinitiv UK 7-10 Years Government Total Market Index (TRXUKGOV710D) para Reino Unido. El periodo muestral abarca desde el 01/01/2019 hasta el 24/05/2024, y todos los datos se han obtenido de Datastream.

En un primer análisis de los datos, puede verse que las series están caracterizadas por tener una media muy cercana a 0, asimetría y mostrar un notable exceso de curtosis, sobre todo las series de índices bancarios, esta cuestión que ya se había mencionado con anterioridad, pone de manifiesto la mayor frecuencia de ocurrencia de eventos extremos en lo que a las rentabilidades respecta, es decir, valores muy altos o muy bajos son más frecuentes (probables) que para el caso de una distribución Normal, lo cual se traduce en colas más densas de la función de densidad de probabilidad y, en definitiva, distribuciones leptocúrticas. Asimismo, otro punto a favor que evidencia esto es que puede verse como se rechaza notablemente la hipótesis de normalidad para todas las series analizadas a través del test de Jarque-Bera.

	EUSTXBKS	FTSEBKS	NSDQBKS	GR 7-10A	UK 7-10A	US 7-10A
Media	0,04	0,01	0,01	-0,01	-0,01	0,00
Varianza	3,86	3,11	4,25	0,16	0,41	0,31
Asimetría	-0,88	-0,28	-0,34	0,57	-0,20	0,30
Exceso de curtosis	11,04	6,30	7,71	3,90	7,58	1,88
J-B	7323,92***	2343,33***	3510,53***	970,3***	3382,02***	228,97***
Observaciones	1407	1407	1407	1407	1407	1407
ADF (1 Lag)	-24,13***	-38,41***	-12,87***	-37,72***	-35,7***	-40,52***
KPSS (5 Lags)	0,12	0,20	0,08	0,22	0,16	0,23
LB (5 Lags)	20,78***	5,61	54,02***	5,26	8,10	9,27*
ARCH Test (5 Lags)	51,71***	26,75***	112,94***	52,84***	56,51***	25,13***

Correlaciones

EUSTXBKS	1,00					
FTSEBKS	0,81	1,00				
NSDQBKS	0,58	0,56	1,00			
GR 7-10A	-0,27	-0,22	-0,13	1,00		
UK 7-10A	-0,05	0,06	0,02	0,66	1,00	
US 7-10A	-0,36	-0,27	-0,19	0,55	0,42	1,00

Nota: J-B es el estadístico de la prueba de normalidad de Jarque-Bera; ADF es el estadístico de la prueba aumentada de raíz unitaria de Dickey-Fuller con constante; KPSS es el estadístico de la prueba de estacionariedad de Kwiatkowski et al. (1992) ; LB es el estadístico de la prueba de autocorrelación de Ljung & Box, (1978). * significativo al 10%, **significativo al 5%, *** significativo al 1%.

Tabla 1. Principales estadísticos de las series utilizadas.




Gráfico 4. Evolución temporal de los índices bancarios utilizados.

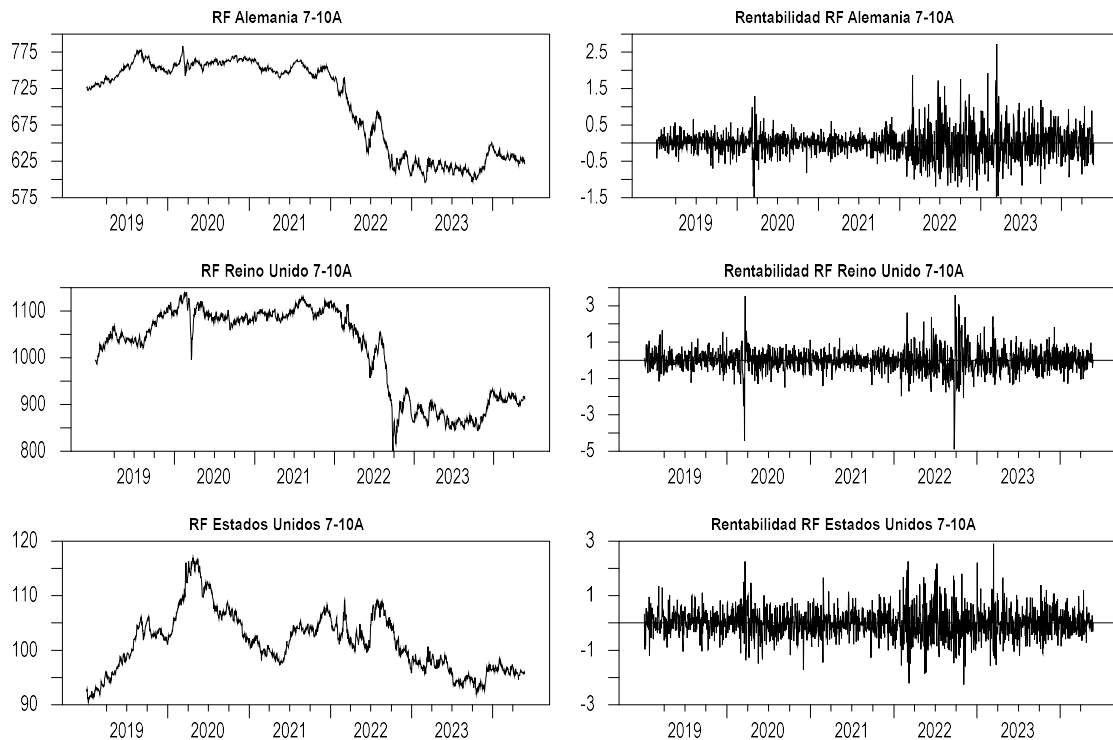


Gráfico 5. Evolución temporal de los índices de renta fija utilizados.

Haciendo uso de los tests de raíces unitarias y estacionariedad, ambos muestran que todas las series de rendimientos son estacionarias a un nivel del 1% de significatividad. Por otro lado, los rendimientos de los índices bancarios de Europa y Estados Unidos muestran evidencia de autocorrelación hasta 5 retardos, mientras que las demás series no muestran evidencia de ello, sin embargo, todas muestran significatividad en el test de heterocedasticidad condicional, siendo en todas significativo al 1%, lo cual muestra, como también se había indicado, una varianza heterogénea y no constante a lo largo del tiempo. Esto también puede verse en los **Gráficos 4 y 5**, en los que puede apreciarse la existencia de agrupamientos de volatilidad, esto es, periodos en los que existe gran variabilidad en la serie, están seguidos por periodos de aún mayor variabilidad, siendo este un comportamiento característico de la heterocedasticidad condicional autorregresiva.

Asimismo, puede verse como los rendimientos de los índices bancarios están altamente correlacionados, sobre todo en el caso de la banca europea y de Reino Unido, mientras que, aunque no de forma tan significativa, estos índices mantienen una correlación negativa con los rendimientos de los índices de renta fija, especialmente con la europea y estadounidense.

4. Resultados

La estimación de los modelos multivariantes GARCH se ha llevado a cabo incluyendo únicamente como exógena el cuadrado de los rendimientos de los índices de renta fija de cada área cada vez, es decir, se estiman tres modelos BEKK y tres modelos DCC los cuales difieren entre sí en la exógena que se incluye en la ecuación de la varianza. Esto es debido a la gran cantidad de parámetros a estimar y de esta forma, a modo de ejemplo ilustrativo, el primer modelo llamado “BEKK GR 7-10A” es el modelo BEKK(1,1) trivariante en el que la variable exógena son los rendimientos al cuadrado del índice de renta fija de Alemania, y su efecto es recogido por los coeficientes $E(i,j)$, y los coeficientes $E(i)$ en el caso de los modelos DCC. Asimismo, los coeficientes $D(i,j)$ en el caso de los modelos BEKK y los $D(i)$ en el caso de los DCC recogen los posibles efectos asimétricos. Para ambos modelos se ha asumido una distribución t-Student dada la curtosis que presentan los rendimientos de los índices.

Para la modelización de la media condicional se ha seleccionado un modelo VAR(1) cuyo orden ha sido seleccionado de acuerdo al criterio de información de Schwarz. Se puede ver que, en media, el primer retardo de los rendimientos de la banca estadounidense es significativo en la ecuación de la media de la banca europea e inglesa, aunque esta significatividad no ocurre a la inversa, pues en la mayoría de los modelos estimados el único coeficiente significativo de la media de la banca estadounidense es el del primer retardo de esta.

Respecto a las ecuaciones de las varianzas condicionales, los primeros retardos del cuadrado de las innovaciones y sus términos de asimetría tienen una influencia significativa solo para el caso de Europa y Estados Unidos pues 4 de los 6 modelos indican significatividad del coeficiente de estos⁸ a un nivel de significatividad convencional del 5%, mientras que para Reino Unido no parece existir una relevancia notable de este elemento en la evolución de su varianza condicional, ya que solo 2 de 6 modelos muestran significatividad del coeficiente $A(2,2)$ y $D(2,2)$ o $D(2)$ simultáneamente al 1%. En definitiva, la volatilidad del sector bancario de Reino Unido durante el periodo de estudio parece que no ha estado condicionada en gran medida por shocks de corto plazo de los rendimientos, aunque prestando atención a los términos de asimetría y su significatividad en 4 de los 6 modelos, esto puede indicar que su volatilidad sí ha estado influida significativamente por caídas en la cotización del índice.

Por otro lado, se puede comprobar que la persistencia, es decir el valor del coeficiente $B(i,i)$, es mucho mayor en términos generales para la banca inglesa, indicando que los periodos de alta volatilidad han tendido a perdurar más en dicho país que en relación al caso europeo y estadounidense. Asimismo, puede verse la significatividad de los grados de libertad de la distribución t-Student de los residuos estandarizados.

Respecto a las variables exógenas, utilizando como proxy el cuadrado del rendimiento de los mencionados índices, todos los modelos BEKK coinciden en señalar la existencia de spillovers de la volatilidad de la renta fija soberana hacia los sectores bancarios europeo e inglés dada la significatividad de los coeficientes $E(1,1)$ y $E(2,1)$, mientras que estos modelos muestran nula evidencia de efectos spillover hacia la banca estadounidense, tal como muestran los coeficientes $E(3,1)$, $E(3,2)$ y $E(3,3)$ los cuales

⁸ Los coeficientes $A(i,i)$ y $D(i,i)$ en los BEKK, $A(i)$ y $D(i)$ en los DCC

carecen de significatividad. Ahora bien, de acuerdo con los modelos DCC, estos efectos hallados desde la renta fija hacia la banca europea e inglesa son rechazados, pues en ninguno de los 3 modelos los coeficientes E(1) y E(2) son significativos, ni siquiera a un 10%, aunque sí que se halla un efecto spillover significativo desde la renta fija estadounidense hacia su sector bancario, tal como indica la significatividad de E(3) en el 3º modelo DCC de la **Tabla 3**.

	BEKK GR 7-10A		BEKK UK 7-10A		BEKK US 7-10A	
	Coef.	P-Valor	Coef.	P-Valor	Coef.	P-Valor
<i>Media EUSTXBKS</i>						
<i>EUSTXBKS (-1)</i>	-0,0433	0,1324	-0,0210	0,5450	-0,0285	0,4001
<i>FTSEBKS (-1)</i>	-0,0286	0,3111	-0,0417	0,1582	-0,0419	0,1339
<i>NSDQBKS(-1)</i>	0,1310	0,0000	0,1291	0,0000	0,1361	0,0000
<i>Constante</i>	0,0700	0,0237	0,0743	0,0210	0,0680	0,0301
<i>Media FTSEBKS</i>						
<i>EUSTXBKS (-1)</i>	-0,0364	0,1558	-0,0126	0,6534	-0,0243	0,3971
<i>FTSEBKS (-1)</i>	-0,0656	0,0131	-0,0862	0,0027	-0,0813	0,0051
<i>NSDQBKS(-1)</i>	0,1295	0,0000	0,1197	0,0000	0,1250	0,0000
<i>Constante</i>	0,0365	0,1678	0,0519	0,0708	0,0454	0,0798
<i>Media NSDQBKS</i>						
<i>EUSTXBKS (-1)</i>	0,0268	0,3085	0,0422	0,2249	0,0373	0,2619
<i>FTSEBKS (-1)</i>	-0,0367	0,0938	-0,0494	0,1056	-0,0454	0,1602
<i>NSDQBKS(-1)</i>	-0,0463	0,0552	-0,0578	0,0299	-0,0521	0,0499
<i>Constante</i>	0,0273	0,4005	0,0392	0,3249	0,0320	0,3622
<i>Ecuación Varianzas</i>						
C(1,1)	0,2334	0,0000	0,0569	0,5797	0,2230	0,0533
C(2,1)	0,0358	0,1954	0,4931	0,0000	0,2404	0,2364
C(2,2)	0,0194	0,4277	0,0895	0,6570	0,3761	0,0001
C(3,1)	0,1184	0,0140	-0,0962	0,2165	0,0572	0,6746
C(3,2)	-0,0958	0,0872	0,1454	0,1924	-0,1162	0,1763
C(3,3)	0,0004	0,9976	0,0000	0,9999	0,1554	0,0265
A(1,1)	0,2998	0,0000	-0,0153	0,9600	0,0753	0,8109
A(1,2)	0,0726	0,0063	-0,1590	0,1600	-0,0810	0,5726
A(1,3)	0,1033	0,0008	-0,0405	0,5870	0,0133	0,9029
A(2,1)	-0,1813	0,0000	0,1300	0,3395	0,0447	0,8180
A(2,2)	0,0092	0,8670	0,4502	0,0000	0,3434	0,0088
A(2,3)	-0,0265	0,6475	0,1317	0,0914	0,0607	0,4500
A(3,1)	-0,0250	0,2774	-0,0456	0,3674	-0,0279	0,5809
A(3,2)	-0,0099	0,5027	-0,1222	0,0069	-0,0977	0,1767
A(3,3)	-0,1200	0,0524	-0,1900	0,0389	-0,1613	0,0990
B(1,1)	0,9022	0,0000	1,0610	0,0000	0,9976	0,0000
B(1,2)	-0,0444	0,0000	0,2026	0,0064	0,1190	0,2583
B(1,3)	-0,0391	0,0000	0,0103	0,7342	-0,0276	0,6040
B(2,1)	0,0564	0,0000	-0,1700	0,0968	-0,1028	0,5102
B(2,2)	1,0127	0,0000	0,6433	0,0000	0,7405	0,0000
B(2,3)	0,0147	0,1089	-0,0348	0,5607	0,0135	0,8796
B(3,1)	-0,0136	0,0275	0,0126	0,7675	0,0099	0,7846
B(3,2)	-0,0035	0,3571	0,0364	0,4389	0,0329	0,3301
B(3,3)	0,9714	0,0000	0,9645	0,0000	0,9586	0,0000
D(1,1)	0,2892	0,0014	0,1960	0,0116	0,2733	0,0007
D(1,2)	0,1118	0,0003	-0,1085	0,3338	-0,0091	0,9482
D(1,3)	0,1087	0,0118	0,0455	0,4875	0,1098	0,1077
D(2,1)	-0,0110	0,8405	0,1669	0,0568	0,1235	0,1371
D(2,2)	0,1319	0,0000	0,3861	0,0927	0,3283	0,1122
D(2,3)	0,0723	0,0342	0,1178	0,2392	0,0685	0,4196
D(3,1)	0,1318	0,0000	0,0833	0,0605	0,0835	0,1124
D(3,2)	0,0661	0,0016	0,0632	0,2855	0,0433	0,4100
D(3,3)	0,2396	0,0000	0,2213	0,1007	0,2427	0,0239
E(1,1)	0,1473	0,0645	0,1008	0,0005	0,2174	0,0505
E(2,1)	0,0836	0,0907	0,1398	0,0000	0,3093	0,0183
E(2,2)	0,0193	0,3380	0,0040	0,7922	0,1302	0,2271
E(3,1)	-0,0644	0,2727	0,0293	0,2237	0,0218	0,8074
E(3,2)	-0,0966	0,0894	0,0155	0,5650	0,0319	0,5520
E(3,3)	-0,0002	0,9984	0,0000	1,0000	0,0780	0,2462
v	6,2439	0,0000	6,4301	0,0000	6,4982	0,0000
<i>AIC</i>	9,9880		10,0010		9,9920	
<i>BIC</i>	10,1820		10,1950		10,1860	
<i>LOGLIK</i>	-6969,4164		-6978,9557		-6972,5713	

Tabla 2. Modelos BEKK estimados.

	DCC GR 7-10A		DCC UK 7-10A		DCC US 7-10A	
	Coef.	P-Valor	Coef.	P-Valor	Coef.	P-Valor
<i>Media EUSTXBKS</i>						
<i>EUSTXBKS (-1)</i>	-0,0307	0,2820	-0,0309	0,2147	-0,0278	0,3892
<i>FTSEBKS (-1)</i>	-0,0372	0,2646	-0,0330	0,1683	-0,0395	0,2229
<i>NSDQBKS(-1)</i>	0,1128	0,0000	0,1109	0,0000	0,1126	0,0000
<i>Constante</i>	0,0943	0,0018	0,0973	0,0011	0,0942	0,0013
<i>Media FTSEBKS</i>						
<i>EUSTXBKS (-1)</i>	-0,0264	0,2521	-0,0272	0,1495	-0,0246	0,3838
<i>FTSEBKS (-1)</i>	-0,0660	0,0253	-0,0634	0,0105	-0,0664	0,0402
<i>NSDQBKS(-1)</i>	0,1101	0,0000	0,1095	0,0000	0,1105	0,0000
<i>Constante</i>	0,0588	0,0308	0,0613	0,0254	0,0589	0,0225
<i>Media NSDQBKS</i>						
<i>EUSTXBKS (-1)</i>	0,0308	0,3676	0,0308	0,2649	0,0304	0,3192
<i>FTSEBKS (-1)</i>	-0,0387	0,1581	-0,0375	0,1465	-0,0380	0,1799
<i>NSDQBKS(-1)</i>	-0,0536	0,0351	-0,0540	0,0477	-0,0538	0,0311
<i>Constante</i>	0,0624	0,0666	0,0658	0,0481	0,0631	0,0424
<i>Ecuación Varianzas</i>						
<i>C(1)</i>	0,0655	0,0564	0,0658	0,0032	0,0681	0,0337
<i>C(2)</i>	0,0289	0,2390	0,0293	0,0849	0,0305	0,1758
<i>C(3)</i>	0,0733	0,2146	0,0761	0,0033	0,0662	0,0605
<i>A(1,1)</i>	0,0483	0,0237	0,0418	0,0405	0,0505	0,0026
<i>A(1,2)</i>	-0,0265	0,0030	-0,0246	0,0075	-0,0264	0,0179
<i>A(1,3)</i>	0,0175	0,2299	0,0191	0,0438	0,0255	0,0011
<i>A(2,1)</i>	0,0230	0,0599	0,0191	0,1271	0,0258	0,0285
<i>A(2,2)</i>	-0,0081	0,5992	-0,0052	0,6562	-0,0098	0,4233
<i>A(2,3)</i>	0,0223	0,1020	0,0237	0,0097	0,0292	0,0000
<i>A(3,1)</i>	0,0286	0,2853	0,0264	0,2069	0,0290	0,1761
<i>A(3,2)</i>	-0,0186	0,5958	-0,0177	0,5312	-0,0218	0,5653
<i>A(3,3)</i>	0,0676	0,0311	0,0715	0,0000	0,0772	0,0000
<i>B(1,1)</i>	0,9008	0,0000	0,9129	0,0000	0,8966	0,0000
<i>B(1,2)</i>	0,0583	0,0622	0,0527	0,0447	0,0576	0,1247
<i>B(1,3)</i>	-0,0349	0,1443	-0,0375	0,0000	-0,0469	0,0001
<i>B(2,1)</i>	-0,0231	0,2373	-0,0166	0,3143	-0,0288	0,0000
<i>B(2,2)</i>	1,0018	0,0000	0,9970	0,0000	1,0039	0,0000
<i>B(2,3)</i>	-0,0317	0,1272	-0,0331	0,0009	-0,0413	0,0000
<i>B(3,1)</i>	-0,0350	0,4717	-0,0266	0,5067	-0,0405	0,1943
<i>B(3,2)</i>	0,0664	0,4108	0,0582	0,3753	0,0657	0,4659
<i>B(3,3)</i>	0,8577	0,0000	0,8556	0,0000	0,8442	0,0000
<i>D(1)</i>	0,0595	0,0018	0,0584	0,0000	0,0571	0,0007
<i>D(2)</i>	0,0245	0,0145	0,0218	0,0290	0,0232	0,0132
<i>D(3)</i>	0,0682	0,0010	0,0628	0,0002	0,0633	0,0003
<i>E(1)</i>	0,0043	0,9543	-0,0140	0,3606	0,1014	0,1320
<i>E(2)</i>	0,0239	0,5135	0,0059	0,6338	0,0883	0,1085
<i>E(3)</i>	0,0478	0,7377	0,0164	0,6691	0,2342	0,0039
<i>α</i>	0,0221	0,0025	0,0220	0,0048	0,0238	0,0069
<i>β</i>	0,9700	0,0000	0,9708	0,0000	0,9663	0,0000
<i>v</i>	6,2011	0,0000	6,2210	0,0000	6,2528	0,0000
<i>AIC</i>	10,075		10,010		10,008	
<i>BIC</i>	10,233		10,167		10,164	
<i>LOGLIK</i>	-6995,4538		-6994,9966		-6993,3003	

Tabla 3. Modelos DCC estimados.

A efectos de diagnosis de los modelos estimados, se muestran en la **Tabla 4** los contrastes de autocorrelación sobre las innovaciones estandarizadas y sus cuadrados, para comprobar de esta forma si aún queda autocorrelación o efectos ARCH sin modelizar.

Con la única excepción de las innovaciones estandarizadas de los rendimientos de la banca europea que, para un orden de 20 retardos aún muestran evidencia de autocorrelación en su media condicional, para las demás series existe una fuerte evidencia en contra de esta. Sin embargo, dado el análisis objeto de este trabajo, lo realmente trascendental es que no existan efectos ARCH sin modelizar para obtener una caracterización de la volatilidad de las series que recoja toda la información posible, de esta forma, se puede ver el gran rechazo hacia la autocorrelación de los cuadrados de los residuos estandarizados tanto a nivel individual como a nivel colectivo mostrando así que no quedan efectos ARCH de las series sin modelizar.

<i>P-valores</i>	BEKK GR 7-10A			BEKK UK 7-10A			BEKK US 7-10A		
	EU	UK	US	EU	UK	US	EU	UK	US
<i>LB (L=10)</i>	0,19	0,75	0,27	0,23	0,58	0,34	0,32	0,38	0,25
<i>McL (L=10)</i>	0,97	0,60	0,35	0,84	0,96	0,04	0,92	0,99	0,44
<i>LB (L=20)</i>	0,03	0,84	0,84	0,06	0,40	0,88	0,05	0,38	0,83
<i>McL (L=20)</i>	0,90	0,84	0,72	0,79	0,71	0,15	0,80	0,88	0,68
<i>LB² (L=10)</i>	0,97	0,60	0,35	0,84	0,96	0,04	0,93	0,99	0,44
<i>LB² (L=20)</i>	0,90	0,84	0,72	0,79	0,71	0,15	0,72	0,88	0,68
<i>MVQ (L=10)</i>		0,62			0,54			0,55	
<i>MVQ (L=20)</i>		0,36			0,14			0,20	
<i>MVQ² (L=10)</i>		0,81			0,78			0,97	
<i>MVQ² (L=20)</i>		0,35			0,60			0,79	
	DCC GR 7-10A			DCC UK 7-10A			DCC US 7-10A		
	EU	UK	US	EU	UK	US	EU	UK	US
<i>LB (L=10)</i>	0,08	0,61	0,45	0,08	0,65	0,45	0,12	0,55	0,41
<i>McL (L=10)</i>	0,33	0,65	0,94	0,21	0,71	0,94	0,50	0,67	0,96
<i>LB (L=20)</i>	0,03	0,67	0,93	0,03	0,69	0,93	0,05	0,61	0,91
<i>McL (L=20)</i>	0,66	0,78	0,89	0,52	0,83	0,89	0,78	0,82	0,89
<i>LB² (L=10)</i>	0,33	0,65	0,94	0,21	0,71	0,94	0,50	0,67	0,96
<i>LB² (L=20)</i>	0,66	0,78	0,89	0,52	0,83	0,89	0,78	0,82	0,89
<i>MVQ (L=10)</i>		0,68			0,68			0,66	
<i>MVQ (L=20)</i>		0,61			0,58			0,60	
<i>MVQ² (L=10)</i>		0,89			0,85			0,98	
<i>MVQ² (L=20)</i>		0,24			0,17			0,40	

Nota: *L* indica el orden de retardo utilizado en cada test; *LB* hace referencia al test de autocorrelación de Ljung & Box (1978) sobre las innovaciones estandarizadas, mientras que *LB²* hace referencia a dicho test pero sobre el cuadrado de las innovaciones estandarizadas; *McL* es el test de McLeod & Li (1983) para efecto ARCH; *MVQ* hace referencia al test de Portmanteau de Hosking (1981) sobre las innovaciones estandarizadas, mientras que *MVQ²* es el mismo test sobre el cuadrado de las innovaciones estandarizadas.

Tabla 4. P-Valores de los contrastes de autocorrelación y efecto ARCH sobre las innovaciones estandarizadas y sus cuadrados.

Respecto a los efectos spillover, para comprobar la existencia de estos, siguiendo a W. Lin (2017), se han realizado test de exclusión de los parámetros que recogen dichos efectos, presentándose los resultados de estos en la **Tabla 5**. Como se puede comprobar, existe evidencia de dichos efectos entre los sectores bancarios europeo e inglés, pues la mayoría de test bidireccionales ejecutados sobre las estimaciones de los modelos indican que al menos alguno de los coeficientes es significativo y, realizando test unidireccionales, se halla evidencia de que el sentido de dichos efectos spillover se ha dado desde el sector bancario inglés hacia el europeo, dada la significatividad de los test sobre los coeficientes que recogen el efecto de un mercado hacia el otro.

En la misma línea puede comprobarse la existencia de transmisión de volatilidad entre la banca estadounidense e inglesa tal como indica la significatividad de la mayoría de test bidireccionales realizados y, en base a los test unidireccionales, estos muestran que el sentido de la transmisión ha sido desde la banca estadounidense hacia la inglesa, pues la mayoría de los test realizados sobre los parámetros A(2,3), B(2,3) y D(2,3) muestran que no se puede rechazar la no significatividad de estos parámetros a niveles de significatividad convencionales⁹.

Por otro lado, respecto a la relación existente entre la banca europea y estadounidense esta no queda del todo clara, dado que la mitad de los test bidireccionales muestran evidencia a favor de la existencia de efectos spillover entre ambos sectores, mientras que la otra mitad rechaza su existencia, este mismo problema ocurre con los test

⁹ Con excepción del realizado en el BEKK UK 7-10A, el cual es significativo al 10%.

unidireccionales, por lo que de esta forma no es posible concluir acerca de la existencia ni la direccionalidad de estos efectos, es por ello que, posteriormente se recurrirá a los resultados obtenidos del enfoque de la conectividad para intentar arrojar luz sobre dicha cuestión.

<i>BEKK GR 7-10A</i>			<i>BEKK UK 7-10A</i>			<i>BEKK US 7-10A</i>			
<i>Bidireccionales</i>									
<i>UK</i>	EU		EU		EU				
	1883,62 (0,00)	UK	13,31 (0,04)	UK	9,00 (0,17)	UK			
<i>US</i>	67,43 (0,00)	24,42 (0,00)	10,04 (0,12)	25,24 (0,00)	9,82 (0,13)	13,8 (0,03)			
	<i>Unidireccionales</i>								
<i>↓Hacia/ Desde→</i>									
<i>EU</i>	EU	UK	US	EU	UK	US	EU	UK	US
		152,96 (0,00)	29,6 (0,00)		8,33 (0,04)	1,5 (0,68)		2,92 (0,4)	3,10 (0,38)
<i>UK</i>	536,63 (0,00)		8,54 (0,04)	4,39 (0,22)		7,12 (0,07)	2,57 (0,46)		3,72 (0,29)
	23,45 (0,00)	11,48 (0,01)		8,82 (0,03)	16,45 (0,00)		6,87 (0,08)	5,59 (0,13)	
DCC GR 7-10A			DCC UK 7-10A			DCC US 7-10A			
<i>Bidireccionales</i>									
<i>UK</i>	EU		EU		EU				
	20,65 (0,00)	UK	51,93 (0,00)	UK	83,35 (0,00)	UK			
<i>US</i>	2,88 (0,58)	8,02 (0,09)	59,12 (0,00)	1041,62 (0,00)	24,26 (0,00)	766,19 (0,00)			
	<i>Unidireccionales</i>								
<i>↓Hacia/ Desde→</i>									
<i>EU</i>	EU	UK	US	EU	UK	US	EU	UK	US
		8,80 (0,01)	2,14 (0,34)		7,21 (0,03)	52,73 (0,00)		6,33 (0,04)	16,87 (0,00)
<i>UK</i>	3,85 (0,15)		2,67 (0,26)	2,72 (0,26)		24,48 (0,00)	40,49 (0,00)		319,1 (0,00)
	1,14 (0,57)	0,82 (0,66)		3,01 (0,22)	1,00 (0,61)		1,9 (0,39)	0,62 (0,74)	

Nota: Los números entre paréntesis son los p-valores correspondientes al estadístico. La hipótesis nula en el caso de los contrastes bidireccionales de los modelos BEKK (y de forma análoga para los DCC) es $H_0: A(i,j)=B(i,j)=D(i,j)=A(j,i)=B(j,i)=D(j,i)=0$, es decir, en la primera tabla, el test entre EU-UK cuyo estadístico es de 1883,62, la hipótesis nula es $H_0: A(1,2)=B(1,2)=D(1,2)=A(2,1)=B(2,1)=D(2,1)=0$, en el caso de los contrastes unidireccionales, lo cuales tratan de contrastar efectos spillover unidireccionales entre los tres mercados, para los modelos BEKK (y de forma análoga para los DCC) es $H_0: A(i,j)=B(i,j)=D(i,j)=0$, es decir, para el caso de la primera tabla, el test entre EU-UK, con estadístico 152,96 hace referencia al contraste sobre los coeficientes que reflejan la influencia de Reino Unido sobre Europa, por tanto la hipótesis nula es $H_0: A(1,2)=B(1,2)=D(1,2)=0$.

Tabla 5. Contrastes para los efectos spillover

Por otro lado, se muestran las correlaciones y varianzas condicionales resultantes de los anteriores modelos. Lo primero sobre lo que se llama la atención es a la alta correlación existente entre la banca europea e inglesa cercana al 0.8 a pesar de la marcha de Reino Unido de la Unión Europea, tal como podía verse en la **Tabla 1**, mientras que la correlación de la banca europea y estadounidense, aunque alta, presenta un nivel más moderado y variable a lo largo del tiempo, asimismo la correlación entre el sector

bancario inglés y estadounidense ha seguido una senda muy parecida a la correlación entre la banca europea y estadounidense.




Gráfico 6. Correlaciones condicionales de los modelos estimados.

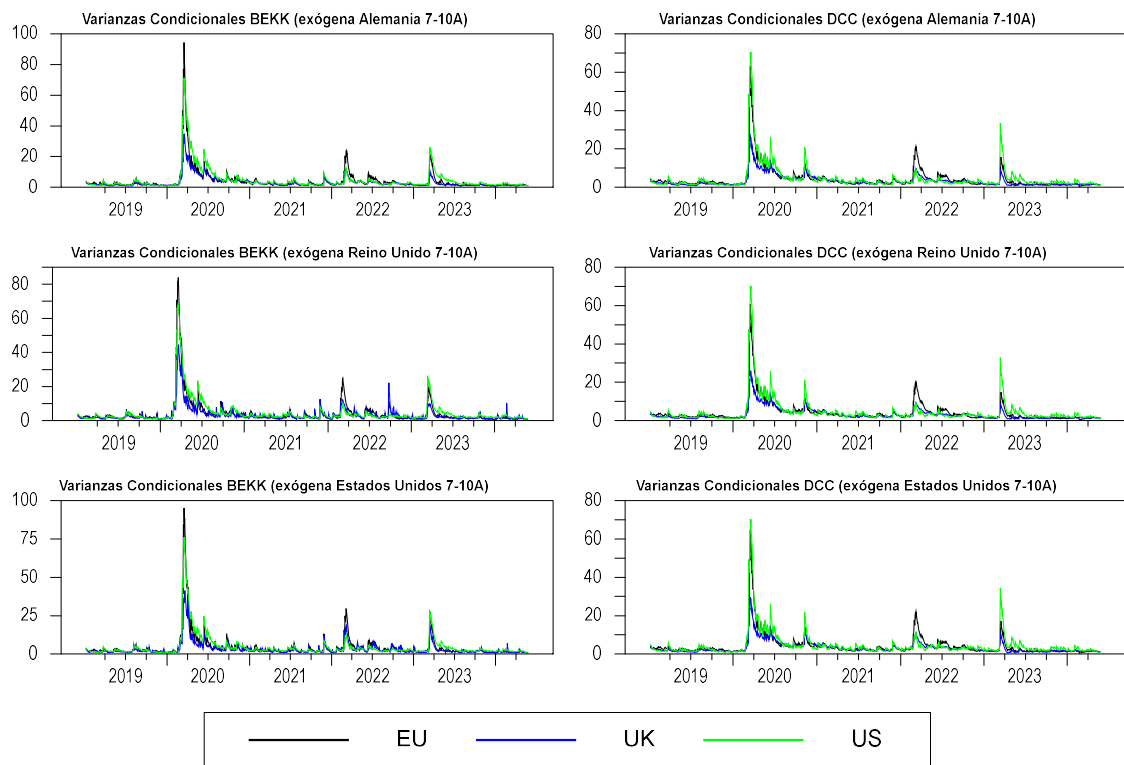


Gráfico 7. Varianzas condicionales de los modelos estimados

Como puede apreciarse en los gráficos, destacan principalmente 3 momentos de interés, el primero de ellos es evidente y se corresponde con el gran repunte de la volatilidad a finales del primer trimestre de 2020 en los 3 sectores bancarios, coincidente con las primeras grandes medidas tomadas en relación a la evolución de la pandemia, lo cual supuso la paralización de la actividad económica durante meses y una lenta recuperación de la normalidad que se extendió hasta finales de 2021 aproximadamente. Se resalta el gran repunte que sufrieron los sectores bancarios europeo y estadounidense frente al Reino Unido el cual, a pesar de haber sufrido un repunte muy notable de su volatilidad, este ha sido de aproximadamente la mitad que en las otras áreas. Como se aprecia en el **Gráfico 6**, la correlación entre los 3 sectores bancarios sufrió un notable repunte, donde la banca inglesa y europea llegaron a una correlación cercana a 1 y, tanto la europea como la inglesa con la estadounidense aumentó de en torno a un 0.4-0.5 a un 0.8, pasando a prácticamente duplicarse.

En segundo periodo de interés es el ocurrido en el primer trimestre de 2022, pues, en febrero de dicho año, Rusia declaraba formalmente la guerra a Ucrania, a lo cual Europa principalmente respondió intentando cortar lazos comerciales y económicos con Rusia con el objetivo de ejercer presión. Dada la dependencia energética que Europa mostraba hacia Rusia, así como el papel relevante que esta tiene en los mercados energéticos internacionales, y ante el panorama de una guerra, es razonable el incremento de la incertidumbre en todo el mundo, y el sector bancario no ha sido menos, pues se puede ver el incremento de volatilidad en estos sectores de las áreas estudiadas en este trabajo. Puede comprobarse también observando el **Gráfico 7** como el sector bancario europeo sufrió el mayor repunte de volatilidad durante dichos acontecimientos.

Por último, el último repunte en la volatilidad de los 3 sectores bancarios se dio a finales del primer trimestre de 2023, fechas en las que el Silicon Valley Bank entraba en problemas de liquidez que posteriormente derivaría en su quiebra debido a un pánico bancario, problema que se extendió a otros bancos estadounidenses alimentando aún más la desconfianza al sector bancario de dicho país y otros lugares como en Europa provocando que el Credit Suisse que ya arrastraba problemas, finalmente cayera y fuese adquirido por UBS en Marzo de 2023, aunque a pesar de esto, el problema quedó relegado a un problema nacional estadounidense. La primera prueba de ello es el mayor repunte de la volatilidad del sector bancario de dicho país en relación con Europa y Reino Unido, llegando incluso a superar el repunte ocurrido al estallido de la guerra de Ucrania. La segunda prueba es la caída en las correlaciones con la banca estadounidense, donde la caída más fuerte se dio con la banca inglesa.

En definitiva, puede verse como existe evidencia de efectos spillover desde la renta fija soberana hacia los sectores bancarios europeo e inglés y poca evidencia hacia el estadounidense, asimismo puede verse el efecto transmisor de volatilidad que la banca inglesa ha tenido hacia la europea, así como la estadounidense hacia la inglesa mientras que entre la banca europea y estadounidense no queda completamente claro la existencia de estos efectos ni de su sentido.

Una vez presentados los resultados de los modelos GARCH multivariantes, puede pasarse a presentar los resultados del enfoque de la conectividad. Puede verse en la **Tabla 6** los índices de conectividad promedio de las series, la columna *DESDE* indica la proporción de la varianza del error de la predicción explicada por las otras series, mientras que la fila *HACIA* indica la proporción que explica la correspondiente serie de las demás; la fila de *Suma* indica la suma de toda la columna correspondiente o fila correspondiente;

la suma de todas estos valores es igual al número de variables del sistema multiplicado por 100 (600 en este caso); la fila de *NETO* indica la diferencia entre *DESDE-HACIA* e indica el carácter transmisor o receptor de volatilidad de la serie; el índice TCI es la proporción entre la suma de *DESDE* (o *HACIA*) dividido entre 600, indicando así que proporción de toda la volatilidad es explicada por las demás series sin contar la propia.

	<i>EUSTXBKS</i>	<i>FTSEBKS</i>	<i>NSDQBKS</i>	<i>UK 7-10A</i>	<i>US 7-10A</i>	<i>GR 7-10A</i>	<i>DESDE</i>
<i>EUSTXBKS</i>	43,91	26,88	13,96	1,47	7,34	6,43	56,09
<i>FTSEBKS</i>	28,47	46,58	14,09	1,07	4,53	5,25	53,42
<i>NSDQBKS</i>	17,46	16,68	58,76	0,76	3,32	3,02	41,24
<i>UK 7-10A</i>	1,82	1,11	0,69	62,83	11,36	22,18	37,17
<i>US 7-10A</i>	9,24	5,83	3,93	10,3	53,99	16,7	46,01
<i>GR 7-10A</i>	7,33	5,58	2,97	19,36	15,34	49,43	50,57
<i>HACIA</i>	64,32	56,09	35,65	32,96	41,9	53,59	284,5
<i>Suma</i>	108,23	102,67	94,41	95,79	95,89	103,02	TCI
<i>NETO</i>	8,23	2,67	-5,59	-4,21	-4,11	3,02	47,42

Nota: La estimación se ha llevado a cabo utilizando un VAR(1), cuyo orden se ha seleccionado de acuerdo al criterio de información de Schwarz.

Tabla 6. Tabla de conectividad.

La columna *DESDE* indica que el principal receptor de volatilidad es la banca europea, seguida de la inglesa, siendo estas las mayores contribuidoras mutuas, ambas seguidas por la banca estadounidense, asimismo, se puede ver que la mayor serie de renta fija contribuidora a la banca europea ha sido la americana, con un 7.34%, mientras que para la banca inglesa ha sido la alemana, con un 5.25% y de nuevo la americana con un 3.32% para su propio sector bancario.

Para la construcción de los índices dinámicos de los **Gráficos 8, 10 y 11** se ha realizado una estimación móvil consistente en una ventana de 252 datos con un horizonte de predicción de 10 días, de esta forma, a diferencia de los índices de la **Tabla 6** los cuales se basan en la descomposición realizada sobre la varianza del error de la predicción del modelo VAR utilizando todo el periodo muestral, en esta estimación móvil se empieza tomando los primeros 252 datos y se realiza la descomposición de la varianza del error de la predicción a 10 días para calcular los correspondientes índices¹⁰, realizando esta estimación móvil hasta el final de la muestra, es lo que permite obtener los índices dinámicos y realizar un análisis más allá del estático.

El índice TCI muestra que, en términos medios, el 47.42% de la varianza del error de la predicción procede de spillovers de otras series, indicando una notable conectividad del sistema. Por otro lado, la fila de *NETO* muestra que la banca europea e inglesa han

¹⁰ Nótese que el periodo de los índices no coincide con el de los datos justamente por este motivo, ya que los índices empiezan a finales de 2019.

tenido en términos medios un carácter transmisor de volatilidad, mientras que la banca estadounidense ha mantenido un carácter receptor en términos generales. En el **Gráfico 8** se muestra la evolución del TCI el cual puede verse que ha mantenido una evolución bastante moderada hasta 2022 cuando comenzó la guerra de Ucrania, donde casi ha llegado a alcanzar el valor del 60%, para posteriormente ir disminuyendo hasta el momento en que sucede la quiebra del Silicon Valley Bank, momentos en los que este índice alcanza su mínimo donde en periodos posteriores vuelve a subir con fuerza y se produce una notable caída hasta situarse ligeramente por debajo del 40% en los últimos periodos muestrales.

Asimismo, puede verse en el **Gráfico 9** lo que previamente se había comentado y que ya mostraba la **Tabla 6**, en amarillo se indican las series que son principalmente importadoras de volatilidad, mientras que las que están en azul indica que estas son las series exportadoras de volatilidad del sistema. Por otro lado, las líneas indican la relación existente entre las series y el sentido general de la transmisión entre estas, así, puede verse la fuerte relación entre la banca europea y la estadounidense, siendo la primera la que exporta volatilidad a la segunda.




Gráfico 8. Evolución del índice TCI.

Asimismo, la banca inglesa y estadounidense muestran una relación moderada, mostrando evidencia de que la primera ha mantenido un papel de transmisor en dicha relación, mientras que, por otro lado, ha existido relación entre la banca europea e inglesa, aunque ha sido relativamente débil, mostrando que el sentido de la transmisión se ha producido desde Europa hacia Reino Unido al contrario de lo evidenciado por los modelos GARCH.

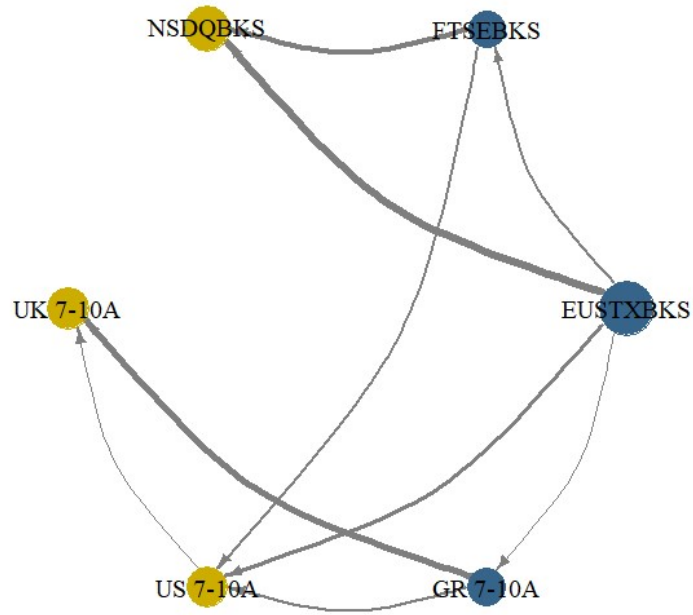


Gráfico 9. Red de conectividad.

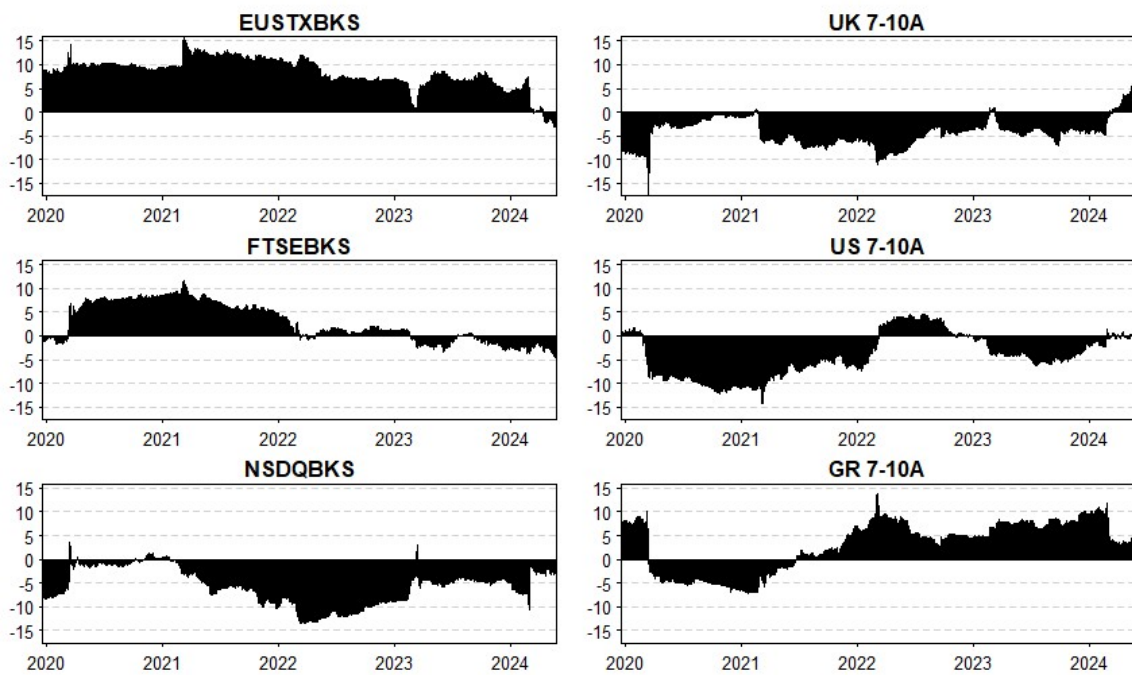


Gráfico 10. Índices netos de spillovers

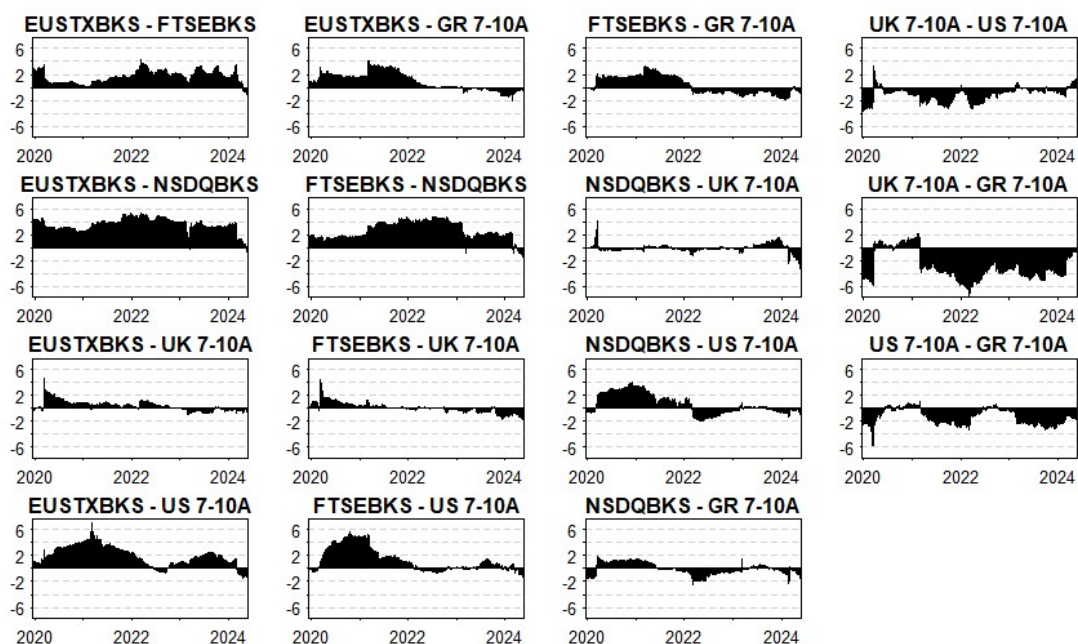


Gráfico 11. Índices netos de spillovers por pares.

Por otro lado, también se muestra el inexistente carácter transmisor de volatilidad desde la renta fija hacia la banca, la cual, de acuerdo con el **Gráfico 9** y **Tabla 6** muestra un carácter receptor, evidenciando un efecto transmisor desde los diferentes sectores bancarios hacia esta. Al mismo tiempo, se muestra en el **Gráfico 10** la evolución de los índices netos de spillover, los cuales proporcionan información acerca de cómo dicho carácter transmisor y receptor han ido evolucionando a lo largo del tiempo. Como puede apreciarse, la banca europea ha mantenido un carácter exportador notable a lo largo de la mayor parte del periodo, exceptuando el año 2024, donde este ha cambiado y, según se muestra en el mencionado gráfico, esta ha sido importadora de volatilidad.

Asimismo, la banca inglesa ha mantenido un carácter mixto a lo largo del periodo de estudio, pasando de tener un marcado rol transmisor desde 2020 hasta principios de 2022, momento a partir del que se ha ido moderando, hasta a principios de 2023 adoptar un carácter receptor que se ha ido acentuando hasta fechas actuales. Ahora bien, puede verse que, así como la banca europea posee un carácter eminentemente transmisor, la banca estadounidense ha mantenido un carácter notoriamente receptor a lo largo del tiempo, acentuándose a principios de 2022 y, aunque este se ha ido moderando desde entonces aún persiste.

Para finalizar, se presentan los índices netos de spillover por pares de series en el **Gráfico 11**, donde se puede apreciar que la banca europea ha tenido un carácter transmisor hacia la banca inglesa y estadounidense durante todo el periodo, asimismo, la banca inglesa ha tenido el papel de exportadora de volatilidad respecto a la estadounidense de forma muy marcada durante todo el periodo.

Otra cuestión relevante es que, aunque la renta fija no había mostrado evidencias de efectos spillover hacia la banca en todo el análisis previo, en estos índices se pudo apreciar que, entre la banca europea y la renta fija alemana, esta última ha ido ganando un carácter transmisor hacia la primera tal como muestra el 1º gráfico de la 2º columna. Esto mismo también ha ocurrido con la banca inglesa y su renta fija, observando el 3º gráfico de la 2º columna se aprecia una dinámica similar, pudiendo verse como la renta fija soberana de

Reino Unido ha ido ganando un rol transmisor hacia su sector bancario sobre todo hacia finales de 2023 y el periodo tomado de 2024. De igual modo, aunque de forma no tan notoria, la renta fija estadounidense también ha adoptado un papel transmisor hacia su sector bancario desde 2022 que ha ido moderándose hacia 2024.

Asimismo, se puede apreciar que la renta fija alemana ha tomado un papel de transmisor neto hacia la banca inglesa desde principios de 2022, carácter que se ha mantenido hasta 2024 donde ha comenzado a moderarse. Esto mismo ha ocurrido hacia la banca estadounidense, la cual ha adoptado un papel de importadora neta de volatilidad de la renta fija alemana desde 2022 para ir moderándose hasta finales de 2023 para volver a repuntar en 2024

5. Conclusiones

El objetivo de este trabajo es doble, pues, por un lado, se ha tratado de analizar la interconexión de los sistemas bancarios europeo, estadounidense e inglés a través de la modelización de las correlaciones y estudio de efectos spillover durante el periodo que abarca desde enero de 2019 a mayo de 2024, así como indagar acerca de si la incertidumbre de los mercados de deuda soberana para el periodo considerado ha influido en la incertidumbre de los sectores bancarios o alguno de ellos. Para ello se ha utilizado dos enfoques metodológicos, el de los modelos GARCH multivariantes y el enfoque de la conectividad de Diebold & Yilmaz (2012).

En primer lugar, a través del enfoque de los modelos GARCH multivariantes se ha hallado evidencia de efectos spillover entre los tres sistemas bancarios, siendo su sentido desde Reino Unido a Europa y desde Estados Unidos a Reino Unido, aunque entre la banca estadounidense y europea no se ha obtenido una evidencia concluyente, asimismo, la banca europea e inglesa han mantenido una correlación muy alta (en torno a un 0.8) durante todo el periodo, evidenciando así un nivel de integración bastante elevado pesar de la salida de Reino Unido de la Unión Europea, poniendo así de manifiesto que, a pesar de ello, si este desea desacoplar su sistema financiero del europeo, es probable que necesite algo más que simplemente abandonar la UE. Por otro lado, el nivel de correlación de la banca inglesa y europea con la estadounidense ha sido más baja (cerca de un 0.4-0.5) y volátil, llegando a un mínimo aproximadamente sobre las fechas en las que se produjeron tensiones en los mercados debido a la quiebra del Silicon Valley Bank, lo cual pone sobre la mesa la fructífera labor de los reguladores del mercado para dar confianza a los inversores y al público en general.

En segundo lugar, a través del enfoque de la conectividad también se han hallado efectos spillover y evidencia de transmisión notable del riesgo entre los sectores bancarios estudiados, siendo la banca europea la principal transmisora en términos generales y la estadounidense la principal receptora en estos términos también, asimismo, a diferencia del enfoque anterior, se muestra una marcada evidencia de transmisión de la banca europea hacia la estadounidense e inglesa, y de esta última hacia la estadounidense. Nótese también que, la metodología de los modelos GARCH multivariantes y el enfoque de la conectividad son notoriamente diferentes e cuanto a la forma de medir la transmisión de la volatilidad, mientras que en el primero se modeliza la matriz de covarianzas de los rendimientos añadiendo la deuda soberana como variable explicativa en las ecuaciones que definen esta, mientras que en el enfoque de la conectividad, se utiliza un VAR con las 6 series, y en base a la descomposición de la varianza se calculan los índices que miden la transmisión y spillovers, por lo que ambas metodologías no son comparables directamente.

En tercer y último lugar, los modelos BEKK muestran evidencia de efecto transmisor de riesgo desde la deuda soberana hacia la banca europea e inglesa, aunque no de forma muy notable, mientras que nula hacia la estadounidense, mientras que los modelos DCC muestran evidencia de que la deuda soberana estadounidense ha tenido un efecto transmisor significativo hacia su sector bancario. Por otro lado, desde el enfoque de la conectividad, se puede ver cómo, aunque no en términos generales, a partir de 2022 la deuda soberana ha adoptado un carácter transmisor hacia sus sectores bancarios nacionales principalmente en el caso inglés y estadounidense, asimismo, se ha

evidenciado que la deuda soberana alemana ha adoptado este mismo carácter hacia la banca inglesa y estadounidense para dicho periodo.

Bibliografía

- Altavilla, C., Pagano, M., & Simonelli, S. (2017). Bank Exposures and Sovereign Stress Transmission. *Review of Finance*, 21(6), 2103-2139. <https://doi.org/10.1093/rof/rfx038>
- Apostolakis, G. N., Floros, C., & Giannellis, N. (2022). On bank return and volatility spillovers: Identifying transmitters and receivers during crisis periods. *International Review of Economics & Finance*, 82, 156-176. <https://doi.org/10.1016/J.IREF.2022.06.009>
- Batten, J. A., Boubaker, S., Kinatader, H., Choudhury, T., & Wagner, N. F. (2023). Volatility impacts on global banks: Insights from the GFC, COVID-19, and the Russia-Ukraine war. *Journal of Economic Behavior & Organization*, 215, 325-350. <https://doi.org/10.1016/J.JEBO.2023.09.016>
- Bauwens, L., Laurent, S., & Rombouts, J. V. K. (2006). Multivariate GARCH models: A survey. *Journal of Applied Econometrics*, 21(1), 79-109. <https://doi.org/10.1002/jae.842>
- Baziki, S. B., Nieto, M. J., & Turk-Ariss, R. (2023). Sovereign portfolio composition and bank risk: The case of European banks. *Journal of Financial Stability*, 65, 101108-101108. <https://doi.org/10.1016/J.JFS.2023.101108>
- Billio, M., Caporin, M., & Gobbo, M. (2006). Flexible Dynamic Conditional Correlation Multivariate GARCH Models for Asset Allocation. *Applied Financial Economics Letters*, 2, 123-130. <https://doi.org/10.1080/17446540500428843>
- Bollerslev, T. (1990). Modelling the Coherence in Short-Run Nominal Exchange Rates: A Multivariate Generalized Arch Model. *The Review of Economics and Statistics*, 72(3), 498-505. JSTOR. <https://doi.org/10.2307/2109358>
- Bollerslev, T., Engle, R. F., & Wooldridge, J. M. (1988). A Capital Asset Pricing Model with Time-Varying Covariances. *Journal of Political Economy*, 96(1), 116-131. JSTOR.
- Bottero, M., Lenzu, S., & Mezzanotti, F. (2020). Sovereign debt exposure and the bank lending channel: Impact on credit supply and the real economy. *Journal of International Economics*, 126, 103328. <https://doi.org/10.1016/j.jinteco.2020.103328>
- Caporin, M., Natvik, G. J., Ravazzolo, F., & Santucci de Magistris, P. (2019). The bank-sovereign nexus: Evidence from a non-bailout episode. *Journal of Empirical Finance*, 53, 181-196. <https://doi.org/10.1016/j.jempfin.2019.07.001>
- Chen, Y., Xu, J., & Miao, J. (2023). Dynamic volatility contagion across the Baltic dry index, iron ore price and crude oil price under the COVID-19: A copula-VAR-BEKK-GARCH-X approach. *Resources Policy*, 81, 103296-103296. <https://doi.org/10.1016/J.RESOURPOL.2023.103296>

- Chen, Y., Zheng, B., & Qu, F. (2020). Modeling the nexus of crude oil, new energy and rare earth in China: An asymmetric VAR-BEKK (DCC)-GARCH approach. *Resources Policy*, 65, 101545-101545. <https://doi.org/10.1016/J.RESOURPOL.2019.101545>
- Chen, Z., Zheng, C., & Hao, X. (2022). Volatility spillover effect between internet finance and banks. *Journal of Business Research*, 141, 512-519. <https://doi.org/10.1016/J.JBUSRES.2021.11.049>
- Choudhry, T., & Jayasekera, R. (2014). Returns and volatility spillover in the European banking industry during global financial crisis: Flight to perceived quality or contagion? *International Review of Financial Analysis*, 36(C), 36-45. <https://doi.org/10.1016/J.IRFA.2014.05.003>
- Diebold, F. X., & Yilmaz, K. (2012). Better to give than to receive: Predictive directional measurement of volatility spillovers. *Special Section 1: The Predictability of Financial Markets*, 28(1), 57-66. <https://doi.org/10.1016/j.ijforecast.2011.02.006>
- 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. JSTOR.
- Engle, R. F., & Kroner, K. F. (1995). Multivariate Simultaneous Generalized Arch. *Econometric Theory*, 11(1), 122-150. JSTOR.
- Gomez-Puig, M., Singh, M. K., & Sosvilla-Rivero, S. (2019). The sovereign-bank nexus in peripheral euro area: Further evidence from contingent claims analysis. *The North American Journal of Economics and Finance*, 49, 1-26. <https://doi.org/10.1016/J.NAJEF.2019.03.021>
- Hosking, J. R. M. (1981). Equivalent Forms of the Multivariate Portmanteau Statistic. *Journal of the Royal Statistical Society: Series B (Methodological)*, 43(2), 261-262. <https://doi.org/10.1111/j.2517-6161.1981.tb01179.x>
- Ibarz, M. A., Lobera, A. B., & Santos, M. A. R. (2022). La curva de tipos y el nexo bancos-deuda pública. *Cuadernos de Información económica*, 289, 17-22.
- Keddad, B., & Schalck, C. (2020). Evaluating sovereign risk spillovers on domestic banks during the European debt crisis. *Economic Modelling*, 88, 356-375. <https://doi.org/10.1016/J.ECONMOD.2019.09.047>
- Koop, G., Pesaran, M. H., & Potter, S. M. (1996). Impulse response analysis in nonlinear multivariate models. *Journal of Econometrics*, 74(1), 119-147. [https://doi.org/10.1016/0304-4076\(95\)01753-4](https://doi.org/10.1016/0304-4076(95)01753-4)
- Koutmos, G. (1996). Modeling the dynamic interdependence of major european stock markets. *Journal of Business Finance & Accounting*, 23(7), 975-988. <https://doi.org/10.1111/j.1468-5957.1996.tb01035.x>

- Kwiatkowski, D., Phillips, P. C. B., Schmidt, P., & Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root? *Journal of Econometrics*, *54*(1), 159-178. [https://doi.org/10.1016/0304-4076\(92\)90104-Y](https://doi.org/10.1016/0304-4076(92)90104-Y)
- Lin, B., Wesseh Jr., P. K., & Owusu Appiah, M. (2014). Oil price fluctuation, volatility spillover and the Ghanaian equity market: Implication for portfolio management and hedging effectiveness. *Energy Economics*, *42*, 172-182. <https://doi.org/10.1016/j.eneco.2013.12.017>.
- Lin, W. (2017). Modeling volatility linkages between Shanghai and Hong Kong stock markets before and after the connect program. *Economic Modelling*, *67*, 346-354. <https://doi.org/10.1016/j.econmod.2017.02.012>
- Ling, S., & McAleer, M. (2003). Asymptotic theory for a vector ARMA-GARCH model. *Econometric Theory*, *19*, 280-310.
- Ljung, G. M., & Box, G. E. P. (1978). On a measure of lack of fit in time series models. *Biometrika*, *65*(2), 297-303. <https://doi.org/10.1093/biomet/65.2.297>
- McLeod, A. I., & Li, W. K. (1983). Diagnostic checking arma time series models using squared-residual autocorrelations. *Journal of Time Series Analysis*, *4*(4), 269-273. <https://doi.org/10.1111/j.1467-9892.1983.tb00373.x>
- Mensi, W., Hammoudeh, S., Nguyen, D. K., & Yoon, S. M. (2014). Dynamic spillovers among major energy and cereal commodity prices. *Energy Economics*, *43*, 225-243. <https://doi.org/10.1016/J.ENECO.2014.03.004>
- Ongena, S., Popov, A., & Van Horen, N. (2019). The Invisible Hand of the Government: Moral Suasion during the European Sovereign Debt Crisis. *American Economic Journal: Macroeconomics*, *11*(4), 346-379. <https://doi.org/10.1257/mac.20160377>
- Pesaran, H. H., & Shin, Y. (1998). Generalized impulse response analysis in linear multivariate models. *Economics Letters*, *58*(1), 17-29. [https://doi.org/10.1016/S0165-1765\(97\)00214-0](https://doi.org/10.1016/S0165-1765(97)00214-0)
- Pesaran, M. H. (2015). *Time Series and Panel Data Econometrics*. OUP Oxford. <https://books.google.es/books?id=7RokCwAAQBAJ>
- Sadorsky, P. (2012). Correlations and volatility spillovers between oil prices and the stock prices of clean energy and technology companies. *Energy Economics*, *34*(1), 248-255. <https://doi.org/10.1016/J.ENECO.2011.03.006>
- Song, F., Cui, J., & Yu, Y. (2022). Dynamic volatility spillover effects between wind and solar power generations: Implications for hedging strategies and a sustainable power sector. *Economic Modelling*, *116*, 106036-106036. <https://doi.org/10.1016/J.ECONMOD.2022.106036>
- Tsay, R. S. (2005). *Analysis of Financial Time Series*. Wiley. https://books.google.es/books?id=ddL4tTLb_08C

- Zhao, H., Li, J., Lei, Y., & Zhou, M. (2022). Risk spillover of banking across regions: Evidence from the belt and road countries. *Emerging Markets Review*, 52, 100919-100919. <https://doi.org/10.1016/J.EMEMAR.2022.100919>
- Zheng, B., Zhang, Y. W., Qu, F., Geng, Y., & Yu, H. (2022). Do rare earths drive volatility spillover in crude oil, renewable energy, and high-technology markets? —A wavelet-based BEKK- GARCH-X approach. *Energy*, 251, 123951-123951. <https://doi.org/10.1016/J.ENERGY.2022.123951>