

**Transmissão de risco e co-movimentos entre os
mercados financeiros e os mercados de
*commodities***

**Análise comparativa da crise financeira global, crise
da dívida soberana e crise da Covid-19**

Mateus Ferreira Neves

Dissertação para obtenção do Grau de Mestre em
Economia

Orientador: Prof. Doutor João Dionísio Monteiro
Co-orientador: Prof. Doutor Tiago Jorge Lopes Afonso

Outubro de 2022

Folha em branco

Declaração de Integridade

Eu, Mateus Ferreira Neves, que abaixo assino, estudante com o número de inscrição M10785 do 2º Ciclo de Economia da Faculdade de Ciências Sociais e Humanas, declaro ter desenvolvido o presente trabalho e elaborado o presente texto em total consonância com o **Código de Integridades da Universidade da Beira Interior**.

Mais concretamente afirmo não ter incorrido em qualquer das variedades de Fraude Académica, e que aqui declaro conhecer, que em particular atendi à exigida referenciação de frases, extratos, imagens e outras formas de trabalho intelectual, e assumindo assim na íntegra as responsabilidades da autoria.

Universidade da Beira Interior, Covilhã 05/10/2022

Mateus Ferreira Neves

Folha em branco

Agradecimentos

Gostaria de agradecer em primeiro lugar à minha família que me apoiou em todo o meu percurso académico, a todos os meus amigos que de alguma forma me apoiaram nesta importante etapa da minha vida, e a toda a gente que direta ou indiretamente contribuiu para o desenvolvimento deste trabalho.

Agradeço também ao professor João Monteiro por ter aceite ser meu orientador, por toda a disponibilidade, auxílio, e conhecimento que partilhou durante a realização deste trabalho.

Folha em branco

Resumo

Este estudo tem como objetivo geral analisar as transmissões de risco e co-movimentos condicionais entre os mercados financeiros (países do G7 e China) e os mercados de *commodities* (Ouro e Petróleo) durante períodos de crises financeiras, nomeadamente a crise financeira global 2007-2009, a crise da dívida soberana e a crise do Covid-19. É realizada uma análise comparativa de forma a compreender as diferenças, em termos de intensidade, entre crises financeiras endógenas e uma crise financeira exógena. Para além de analisar os padrões de transmissão de risco entre estes mercados durante os períodos de crises financeiras, são também utilizados procedimentos de análise de co-movimentos, para testar a hipótese de o Ouro ser um ativo de reserva de valor em tempos de incerteza.

De forma a alcançar os objetivos estabelecidos para o presente estudo foram recolhidos para os três períodos em análise as cotações de fecho diárias dos principais índices acionistas dos mercados do G7 e da China, representados pelos índices CAC40, CSI300, DAX30, FTSE100, MIB, NIKKEI, TSX e S&P500. Para as *commodities* foram recolhidas as cotações de fecho diárias dos contratos de futuros para o Ouro, Brent e WTI (*West Texas Intermediate*).

A análise dos processos de transmissão de risco entre os mercados acionistas e os mercados de *commodities*, mais concretamente os efeitos de co-volatilidade entre os mercados, é realizada recorrendo ao modelo BEKK-diagonal. De forma a examinar os co-movimentos de variações de preços entre os mercados acionistas nacionais e os mercados de *commodities* é utilizado o modelo DCC-MGARCH para analisar as correlações condicionais dinâmicas.

Os resultados indicam que a crise Covid-19 (de natureza exógena à economia), face às crises endógenas, foi a que apresentou maiores intensidades de transmissão de risco entre os índices financeiros e os mercados do petróleo. Relativamente às transmissões entre os índices financeiros e o mercado do Ouro, foi durante a crise financeira global 2007-2009 que a maioria dos países verificaram as maiores intensidades de transmissão de risco. Os resultados mostram que os níveis de transmissão de risco verificados entre os mercados financeiros e o mercado do petróleo são sempre superiores aos valores verificados entre os mercados financeiros e o mercado do Ouro. A hipótese de o Ouro ser um bom ativo de reserva de valor em tempos de incerteza foi rejeitada dado que em nenhum período se verificaram correlações condicionais médias negativas ou nulas entre o Ouro e os mercados financeiros. No entanto o Ouro apresenta-se como um ativo com melhores características para diversificação do portefólio comparativamente ao petróleo.

Os resultados desta pesquisa contribuem para uma melhor compreensão dos efeitos de transmissão de risco entre o mercado do Ouro, do Petróleo e dos mercados financeiros em diferentes situações de crise. São de elevado interesse para os vários agentes económicos porque podem oferecer informação relevante na construção de modelos eficientes de mitigação do risco e na implementação de políticas apropriadas em períodos de *stress* económico.

Palavras-chave

Crise financeira global; Dívida soberana; Covid-19; *Commodities*; Ouro; Petróleo; Mercados financeiros; Transmissão de volatilidade; Correlação condicional; Modelo diagonal-BEKK; Modelo DCC-MGARCH

Folha em branco

Abstract

This study aims to examine the volatility spillovers and conditional co-movements between the financial markets (G7 countries and China) and the commodity market (Gold and Oil) in periods of financial stress. A comparative analysis is conducted between the global financial crisis of 2007-2009, the sovereign debt crisis and the Covid-19 crisis, in order to understand the differences, in terms of intensity, between an exogenous crisis and two endogenous crises. In addition to analyzing the patterns of risk transmission between these markets during periods of financial crises, co-movement analysis procedures are also used to test the hypothesis of gold being a safe haven in periods of financial stress.

To accomplish our objectives, we collected data for the time span corresponding to the three crises periods. We used daily closing prices of the main stock market indexes of the G7 countries and China, represented by the stock indices CAC40, CSI300, DAX30, FTSE100, MIB, NIKKEI, TSX and S&P500. Regarding commodities, we collected daily closing prices for future contracts of Gold, Brent and WTI (West Texas Intermediate).

To analyse the volatility spillovers between the stock market and the commodity market we employed the diagonal-BEKK model; to examine the co-movements of the price variation between the stock market and the commodity market we have used the DCC-MGARCH model to obtain the dynamic conditional correlations.

The results indicate that the Covid-19 crisis (an exogenous crisis) had the greatest impact on the volatility spillover between the stock markets and the oil market compared with endogenous crises. Regarding the volatility spillover between the stock markets and the gold market, it was during the global financial crisis 2007-2009 that the greatest spillover intensities took place. Furthermore, the results indicate that the spillover levels between the stock markets and the oil market are always superior to the ones verified between the stock market and the gold market. The hypothesis of gold being a safe haven in periods of financial stress is rejected because there were no negative or even zero conditional correlations between the gold market and the stock markets. However, gold presents itself as a better alternative to portfolio diversification compared to oil.

Our research provides a better understanding of the volatility spillover effect between the gold, oil and the stock markets in periods of crisis. It provides valuable information to the

several economic agents because it helps in the construction of efficient risk mitigation models and in the implementation of appropriate policy in periods of economic stress.

Keywords

Global financial crisis; Sovereign debt crisis; Covid-19 crisis; Commodities; Gold; Oil; Stock markets; Volatility spillovers; Conditional correlation; Diagonal-BEKK model; DCC-MGARCH model

Folha em branco

Índice

Lista de Figuras	xvi
Lista de Tabelas	xviii
Lista de Acrónimos	xxi
1. Introdução	1
2. Revisão de literatura.....	4
2.1. Mecanismos teóricos de transmissão de variações entre o preço do petróleo e os mercados acionistas	5
2.2. Evidência empírica sobre a relação entre o preço do petróleo e o desempenho dos mercados acionistas	7
2.3. Relação entre choques no preço do petróleo e o mercado acionista.....	9
2.4. Relação entre o Ouro (como ativo de reserva de valor) e os mercados financeiros	11
2.5. Relação entre a volatilidade dos mercados de <i>commodities</i> e dos mercados acionistas	12
2.5.1. Conceito de Volatilidade.....	12
2.5.2. Evidência empírica dos efeitos <i>spillover</i> entre mercados acionistas e mercados de <i>commodities</i> (petróleo e Ouro).	14
2.6. Relações entre mercados financeiros e mercados de <i>commodities</i> durante as crises financeiras	16
2.6.1. A crise pandémica Covid-19 e o aumento do risco nos mercados.....	16
2.6.2. Breve descrição da crise financeira global (2007-2009) e da crise da dívida soberana (2010-2013).	17
2.6.3. Evidência empírica dos efeitos <i>spillovers</i> entre mercados acionistas e de <i>commodities</i> durante períodos de crises económico-financeiras	18
3. Dados e Metodologia	22
3.1. Dados.....	22
3.2. Testes de raízes unitárias e de cointegração	25
3.3. Modelos multivariados de Heteroscedasticidade Condicional Autorregressiva	27

3.3.1.	Modelo BEKK-Diagonal – GARCH	28
3.3.2.	Modelo com Correlação Condicional Dinâmica - DCC- MGARCH.....	30
4.	Resultados e Discussão.....	33
4.1.	Estatísticas Descritivas.....	33
4.2.	Testes de raízes unitárias e de cointegração	39
4.3.	Modelo BEKK-Diagonal.....	42
4.4.	Modelo DCC-MGARCH	46
4.5.	Discussão.....	53
5.	Conclusões.....	56
6.	Bibliografia	59
7.	Apêndices	67
	Apêndice (A) - Histogramas e ajustamentos das funções de densidade dos retornos dos índices accionistas do G7 e da China e das séries do petróleo e do Ouro.	67
	Apêndice (B) - Outputs do modelo BEKK-Diagonal no período da crise financeira global 2007-2009.....	69
	Apêndice (C) - Outputs do modelo BEKK-Diagonal no período da crise da dívida soberana	74
	Apêndice (D) - Outputs do modelo BEKK-Diagonal no período da crise da Covid-19...	79
	Apêndice (E) - Outputs do modelo DCC-MGARCH no período da crise da Covid-19....	84
	Apêndice (F) - Outputs do modelo DCC-MGARCH no período da crise da dívida soberana	85
	Apêndice (G) - Outputs do modelo DCC-MGARCH no período da crise financeira global 2007-2009.....	86
	Apêndice (H) - Gráficos das correlações condicionais dinâmicas do modelo DCC-MGARCH no período da crise da Covid-19	87
	Apêndice (I) - Gráficos das correlações condicionais do modelo DCC-MGARCH no período da crise da Dívida Soberana.....	91
	Apêndice (J) - Gráficos das correlações condicionais do modelo DCC-MGARCH no período da crise financeira global 2007-2009	95

Folha em branco

Lista de Figuras

Figura 1: Evolução dos índices acionistas do G7 e da China, do petróleo e do Ouro durante a crise financeira global (unidade.: logaritmo da série)	24
Figura 2: Evolução dos índices acionistas do G7 e da China, do petróleo e do Ouro durante a crise da dívida soberana (unidade.: Logaritmo da série)	24
Figura 3: Evolução dos índices acionistas do G7 e da China, do petróleo e do Ouro durante a crise da Covid-19 (unidade.: Logaritmo da série).....	25
Figura 4: Correlações condicionais, DCC-MGARCH, no continente americano (S&P500, TSX, WTI, Ouro) no período da crise financeira global 2007-2009.....	52
Figura 5: Distribuição dos retornos no período da crise financeira global 2007-2009.....	67
Figura 6: Distribuição dos retornos no período da crise da dívida soberana	67
Figura 7: Distribuição dos retornos no período da crise do Covid-19.....	68
Figura 8: Correlações DCC-MGARCH no continente americano (S&P500, TSX, WTI, Ouro)	87
Figura 9: Correlações DCC-MGARCH no continente asiático (CSI300, NIKKEI, Brent, Ouro)	88
Figura 10: correlações DCC-MGARCH no continente europeu (CAC40, DAX, FTSE100, MIB, Brent, Ouro)	89

Folha em branco

Lista de Tabelas

Tabela 1: Variação do preço real do petróleo e principais fatores.....	10
Tabela 2: Estatísticas descritivas do período da crise financeira global 2007-2009.....	36
Tabela 3: Estatísticas descritivas do período da crise da dívida soberana.....	37
Tabela 4: Estatísticas descritivas do período da crise Covid-19.....	38
Tabela 5: Resultados dos testes de estacionariedade ADF e PP.....	40
Tabela 6: Teste de cointegração Johansen e seleção de modelos para as equações da média condicional na estimação do modelo BEKK-diagonal	41
Tabela 7: Teste de cointegração Johansen e seleção de modelos para as equações da média condicional na estimação do modelo DCC-MGARCH	42
Tabela 8: Estimativas dos coeficientes dos efeitos de transmissão dos choques dos retornos não-esperados e das co-volatilidades anteriores nas co-volatilidades subsequentes no modelo BEKK (1,1) - diagonal.....	44
Tabela 9: Estimação do Modelo VAR(1) – DCC-MGARCH(1,1) para os mercados acionistas americanos e o mercado de <i>commodities</i> (S&P500, TSX, WTI, Ouro) no período Covid-19	47
Tabela 10: Estimação do Modelo VAR(1) – DCC-MGARCH(1,1) para os mercados acionistas americanos e o mercado de <i>commodities</i> (S&P500, TSX, WTI, Ouro) no período da dívida soberana.....	48
Tabela 11: Estimação do Modelo VECM(1) – DCC-MGARCH(1,1) para os mercados acionistas americanos e o mercado de <i>commodities</i> (S&P500, TSX, WTI, Ouro) no período da crise financeira global 2007-2009.....	48
Tabela 12: Modelo VECM (1) – BEKK (1,1) – diagonal; CAC40, Brent e Ouro.....	69
Tabela 13: Modelo VECM (1) – BEKK (1,1) – diagonal; CSI300, Brent e Ouro.....	70
Tabela 14: Modelo VAR (1) – BEKK (1,1) – diagonal; DAX, Brent e Ouro	70
Tabela 15: Modelo VECM(1) – BEKK (1,1) – diagonal; FTSE100, Brent e Ouro	71
Tabela 16: Modelo VAR (1) – BEKK (1,1) – diagonal; MIB, Brent e Ouro.....	71
Tabela 17: Modelo VECM (1) – BEKK (1,1) – diagonal; NIKKEI, Brent e Ouro	72
Tabela 18: Modelo VAR (1) – BEKK (1,1) – diagonal; S&P500, WTI e Ouro.....	72
Tabela 19: Modelo VAR (1) – BEKK (1,1) – diagonal; TSX, WTI e Ouro	73
Tabela 20: Modelo VECM (1) – BEKK (1,1) – diagonal; Ouro, WTI e Brent	73
Tabela 21: Modelo VECM (1) – BEKK (1,1) – diagonal; CAC40, Brent e Ouro.....	74
Tabela 22: Modelo VAR (1) – BEKK (1,1) – diagonal; CSI300, Brent e Ouro	75
Tabela 23: Modelo VAR (1) – BEKK (1,1) – diagonal; DAX, Brent e Ouro.....	75
Tabela 24: Modelo VAR (1) – BEKK (1,1) – diagonal; FTSE100, Brent e Ouro.....	76

Tabela 25: Modelo VAR (1) – BEKK (1,1) – diagonal; MIB, Brent e Ouro.....	76
Tabela 26: Modelo VAR (1) – BEKK (1,1) – diagonal; NIKKEI, Brent e Ouro.....	77
Tabela 27: Modelo VAR (1) – BEKK (1,1) – diagonal; S&P500, WTI e Ouro	77
Tabela 28: Modelo VAR (1) – BEKK (1,1) – diagonal; TSX, WTI e Ouro	78
Tabela 29: Modelo VAR (1) – BEKK (1,1) – diagonal; Ouro, WTI e Brent	78
Tabela 30: Modelo VAR (1) – BEKK (1,1) – diagonal; CAC40, Brent e Ouro	79
Tabela 31: Modelo VAR (1) – BEKK (1,1) – diagonal; CSI300, Brent e Ouro.....	80
Tabela 32: Modelo VECM (1) – BEKK (1,1) – diagonal; DAX, Brent e Ouro.....	80
Tabela 33: Modelo VAR (1) – BEKK (1,1) – diagonal; FTSE100, Brent e Ouro.....	81
Tabela 34: Modelo VAR (1) – BEKK (1,1) – diagonal; MIB, Brent e Ouro	81
Tabela 35: Modelo VAR (1) – BEKK (1,1) – diagonal; NIKKEI, Brent e Ouro.....	82
Tabela 36: Modelo VAR (1) – BEKK (1,1) – diagonal; S&P500, WTI e Ouro	82
Tabela 37: Modelo VAR (1) – BEKK (1,1) – diagonal; TSX, WTI e Ouro.....	83
Tabela 38: Modelo VECM (1) – BEKK (1,1) – diagonal; Ouro, WTI e Brent	83
Tabela 39: Estimação do Modelo VECM(1) - DCC-MGARCH(1,1) para os mercados acionistas Europeus e os mercados de <i>commodities</i> (CAC40, DAX, FTSE100, MIB, Brent, Ouro)	84
Tabela 40: Estimação do Modelo VECM(1) - DCC-MGARCH(1,1) para os mercados acionistas Asiáticos e os mercados de <i>commodities</i> (CSI300, NIKKEI, Brent, Ouro)	84
Tabela 41: Estimação do Modelo VAR(1) - DCC-MGARCH(1,1) para os mercados acionistas Europeus e o mercado de <i>commodities</i> (CAC40, DAX, FTSE100, MIB, Brent, Ouro)	85
Tabela 42: Estimação do Modelo VAR(1) - DCC-MGARCH(1,1) para os mercados acionistas Asiáticos e o mercado de <i>commodities</i> (CSI300, NIKKEI, Brent, Ouro)	85
Tabela 43: Estimação do Modelo VAR(1) - DCC-MGARCH(1,1) para os mercados acionistas Europeus e o mercado de <i>commodities</i> (CAC40, DAX, FTSE100, MIB, Brent, Ouro)	86
Tabela 44: Estimação do Modelo VAR(1) - DCC-MGARCH(1,1) para os mercados acionistas Asiáticos e o mercado de <i>commodities</i> (CSI300, NIKKEI, Brent, Ouro)	86

Folha em branco

Lista de Acrónimos

PIB	Produto Interno Bruto
EUA	Estados Unidos da América
OECD	Organização para a Cooperação e Desenvolvimento Económico
ICE	Intercontinental Exchange
WTI	West Texas Intermediate
NYMEX	New York Mercantile Exchange
CME	Chicago Mercantile Exchange
VAR	Vetores Autoregressivos
CAPM	Capital Asset Pricing
GARCH	Generalized Autoregressive Conditional Heteroskedasticity
DCC	Dynamic Conditional Correlation
ETF	Exchange Traded Funds
FTSE	Financial Times Stock Exchange
S&P	Standard & Poor's
CAC	Cotation Assistée en Continu
TSX	Toronto Stock Exchange
DAX	Deutscher stock index
MIB	Milano Indice di Borsa
NIKKEI	Nihon Keizai Shimbun
CSI	China Securities Index
QMV	Quase Máxima Verosimilhança

Folha em branco

1. Introdução

A doença Covid-19, declarada pandemia em março de 2020, revelou-se um verdadeiro desafio para a economia global. A enorme escala do problema e o nível elevado de propagação do vírus forçaram os responsáveis políticos a tomarem medidas extremas com enormes custos económicos de forma a abrandar a sua propagação. Estes traduziram-se em confinamentos, quer a nível regional, nacional e internacional, que, devido ao nível de globalização e de integração dos mercados, causaram danos económicos e constrangimentos na cadeia de abastecimento a nível mundial. A literatura sobre as implicações da doença Covid-19, sentidas nos mercados financeiros e de *commodities* à escala global, revela que o aumento da incerteza afetou negativamente estes mercados (Sattar *et al.*, 2020; Bouhali *et al.*, 2021; Çelik *et al.*, 2020; Wang *et al.*, 2021) e provocou perdas na economia global.

Esta dissertação tem como objeto de estudo os mercados acionistas dos países do G7 e da China, e os mercados de futuros de *commodities* do petróleo e do Ouro. O G7 é um grupo informal que reúne os líderes das sete economias mais avançadas e industrializadas do mundo. A China, apesar de ser simultaneamente uma das maiores economias e de ser o país mais populoso do mundo, tem um PIB per capita demasiado baixo, sendo por isso considerado um país em desenvolvimento, razões que levaram a que nunca estivesse inserida no G7. Todavia, a China é considerada relevante para o presente estudo pela preponderância que tem como consumidor de petróleo, posicionando-se apenas atrás dos Estados Unidos da América (EUA), com cerca de 14% do consumo global de petróleo em 2019¹. Em 2021 estes oito países representavam cerca de 62.56% do PIB nominal global, cerca de 49.67% do PIB em termos de paridade do poder de compra² e cerca de 28.147% da população mundial³.

Segundo a Organização para a Cooperação e Desenvolvimento Económico (OECD, 2020)⁴ todos os países deste grupo, com exceção da China, foram penalizados no crescimento do PIB. Todos apresentaram, em 2020, taxas de crescimento do PIB negativas: Canadá com -5.4%, França e Itália ambos com -9.1%, Alemanha com -5.5%, Estados Unidos da América com -3.7%, Reino Unido com -11.2% e o Japão com -5.3%. Apenas a China registou um crescimento positivo de 1.8%.

¹ [U.S. Energy Information Administration \(EIA\) \(2019\)](#)

² [Countries by Projected GDP 2021 - StatisticsTimes.com](#)

³ [Countries by population 2021 - StatisticsTimes.com](#)

⁴ [OECD Economic Outlook, December 2020 | Turning hope into reality](#)

O petróleo e o Ouro são as *commodities* consideradas no presente estudo porque são duas das *commodities* mais transacionadas nos mercados de futuros e classificam-se como das mais importantes para a economia mundial. Por esta razão são frequentemente inseridas pelos investidores nos seus portefólios de investimentos como forma de diversificação. O petróleo é a principal fonte de energia global, é um ativo volátil e o seu preço tende a incorporar informação útil na previsão do preço de outros ativos financeiros e indicadores económicos. O Ouro é um ativo de reserva de valor frequentemente utilizado pelos investidores como forma de cobertura e redução de risco e visto como uma forma de preservar valor em tempos de incerteza.

Este estudo tem como objetivo investigar as relações de interdependência e de transmissão de informação e de risco entre os mercados acionistas do G7 e da China e os mercados de *commodities*, fazendo uma análise comparativa entre os três períodos de crise mais recentes: crise financeira global 2007-2009, crise da dívida soberana e crise da Covid-19. Para captar as inter-relações de dependência entre a situação económica e financeira de cada país e os mercados de energia e de ativos de reserva de valor, representados pelos preços de futuros de petróleo bruto e do Ouro, foram considerados os principais índices acionistas de cada país: S&P500, FTSE100, S&P/TSX, CAC40, DAX, FTSE100, MIB, NIKKEI 225 e o CSI 300, para representar, respetivamente, os EUA, Reino Unido, Canadá, França, Alemanha, Itália, Japão e China. Em relação às *commodities*, o preço do petróleo é representado pelo preço dos contratos de futuros do Brent, transacionados na *Intercontinental Exchange (ICE)*, futuros do *WTI (West Texas Intermediate) crude oil*, transacionados na *New York Mercantile Exchange (NYMEX)* e o preço do Ouro é representado pelo preço dos contratos de futuros do Ouro, transacionados na *Chicago Mercantile Exchange (CME)*.

Este trabalho contribui para o corpo de literatura sobre as relações entre os mercados financeiros, o preço do petróleo e o preço do Ouro ao examinar os efeitos de transmissão de risco que crises financeiras (endógenas) e uma crise pandémica global (exógena) produzem nos mercados financeiros e de *commodities*, contribuindo também para a crescente literatura envolvendo a crise provocada pela Covid-19. São utilizados dados diários para captar as relações de inter-dependência e de transmissão de informação e de volatilidade entre mercados, e neste âmbito captar as principais diferenças entre uma crise endógena e uma crise exógena. A crise financeira de 2007-2009, foi uma crise endógena que teve origem no interior da economia norte-americana, fruto da desregulação do sistema bancário, da falta de ética dos participantes envolvidos no mercado, nomeadamente dos bancos e das agências de *rating*, que levou ao colapso de grandes instituições financeiras e que, gradualmente, se propagou às restantes economias mundiais. Os efeitos desta crise

tornaram o ambiente propício ao surgimento da crise da dívida soberana em 2010 em que vários países europeus receberam ajudas externas face às suas dificuldades em pagar ou refinar as suas dívidas públicas.

A crise pandémica Covid-19 é uma crise exógena, consistindo num evento inesperado, que ocorreu fora da esfera económica, mas que trouxe inevitavelmente efeitos negativos às economias mundiais. A crise financeira de 2007-2009 e a crise da dívida soberana provocaram choques negativos do lado da procura. A crise pandémica Covid-19 fez sentir os seus efeitos mais acentuadamente do lado da oferta. Ambas as crises têm vários fatores em comum, entre eles a incerteza, que corresponde a um aumento do risco sistémico que não é possível quantificar e cujos impactos são imprevisíveis, o facto de ter havido quedas significativas nos principais índices acionistas, e as reações das autoridades monetárias e fiscais que em ambas as crises intervieram de forma a limitar os efeitos adversos nas economias.

Este trabalho está estruturado da seguinte forma. A secção 2 procede à revisão de literatura, onde são contextualizadas teoricamente as diferentes abordagens na análise das relações entre os mercados financeiros e os mercados do Ouro e do petróleo e apresentadas as respectivas evidências empíricas. A secção 3 contém a apresentação dos dados e os procedimentos metodológicos aplicados no estudo. Assume aqui particular destaque a utilização de modelos multivariados de volatilidade condicional autorregressiva, que servem de suporte à análise das relações de interdependência e de transmissão de risco entre os mercados financeiros e os mercados de *commodities*. Na secção 4 são apresentadas e analisadas as propriedades e testes estatísticos de adequação das séries financeiras ao estudo da transmissão e das interdependências de volatilidade. São apresentados e analisados os resultados das relações de transmissão de risco e dos comovimentos entre os vários mercados, a que se segue uma discussão dos resultados obtidos *per se* e também no contexto de uma abordagem comparativa com resultados e evidências obtidas noutros estudos com objectivos semelhantes e afins. Por último, a secção 5 apresenta as conclusões do estudo e possíveis implicações de política económica.

2. Revisão de literatura

Os mercados financeiros desempenham um papel importante na atividade económica. Eles são, de certo modo, o espelho da saúde da economia de cada país, principalmente quando nos referimos aos países desenvolvidos. Quando são criadas novas empresas, quando as empresas crescem e a economia se expande, os investidores e empresas recorrem aos mercados financeiros para investir e obter financiamento e, assim, beneficiar de uma economia em crescimento. As economias crescem e as suas estruturas produtivas, financeiras e organizacionais evoluem ao longo do tempo. Estas mudanças e a abertura aos mercados internacionais de bens e serviços e aos mercados financeiros contribuem para o estabelecimento de relações de interdependência e aumento da frequência de choques e de crises financeiras de âmbito global. Os investidores estão atentos ao risco potencial dos mercados financeiros e de *commodities* e adotam estratégias, como a diversificação de portfolios e a compra/venda de produtos derivados, como forma de atenuar o risco e limitarem as suas perdas.

Nas duas últimas décadas os mercados financeiros internacionais tornaram-se progressivamente mais voláteis como consequência da liberalização financeira e da abertura das economias. Como consequência, o fluxo de investidores para os mercados financeiros e de *commodities*, que especulam sobre os preços, aumentou significativamente trazendo mais liquidez aos mercados.

Esta mudança nos mercados atrai cada vez mais o interesse dos académicos, dos profissionais do sector e dos decisores políticos, associados à regulação e supervisão, para o estudo da volatilidade nos mercados. Compreender as interdependências e os padrões de transmissão de informação e de volatilidade entre os vários mercados é essencial tanto para os investidores como para as entidades decisoras ligadas à regulação e supervisão dos mercados.

Nas secções seguintes procedemos à revisão de literatura sobre as relações de interdependência e de mecanismos teóricos de transmissão de informação e de risco entre os mercados financeiros e os mercados de *commodities* do petróleo bruto e do Ouro. São também apresentadas as principais evidências empíricas relativas às inter-dependências e mecanismos de transmissão de informação e de risco entre os mercados financeiros e de *commodities*.

2.1. Mecanismos teóricos de transmissão de variações entre o preço do petróleo e os mercados acionistas

Degiannakis *et al.*, (2018) consideram que as variações do preço do petróleo podem transmitir-se e afetar o comportamento dos mercados acionistas através de quatro canais: canal de avaliação de ativos empresariais, canal de política monetária, canal de produção agregada da economia e o canal de incerteza⁵.

O mecanismo de avaliação de ativos é o canal direto através do qual o preço do petróleo influencia os mercados financeiros e, em particular, o mercado acionista. A teoria económica sugere que os preços correntes das ações das empresas refletem os *cash-flows* futuros descontados e as taxas de desconto utilizadas, assente, de forma simplificada, na expressão seguinte:

$$P_{i,t} = \sum_{n=t+1}^N \left[\frac{E(CF_n)}{(1+E(r))^n} \right] \quad (1)$$

onde $P_{i,t}$ representa o preço atual da ação, (CF_n) o valor do *cash-flow* futuro no período n , (r) o valor da taxa de desconto e $E(.)$ o operador de valor esperado.

Segundo o modelo de avaliação dos *cash-flows* descontados das empresas, a rendibilidade da ação é afetada por fatores que podem alterar os *cash-flows* esperados e/ou a taxa de desconto, incluindo os preços do petróleo. Uma variação positiva (negativa) do preço do petróleo tenderá a exercer um efeito negativo (positivo) nos *cash-flows* futuros da empresa, consoante esta seja consumidora (produtora) de petróleo (Mohanty e Nandha, 2011). Numa empresa consumidora de energia, e sendo os inputs de energia derivados do petróleo um dos seus principais fatores de produção, um aumento do preço do petróleo resulta num aumento dos custos de produção (assumindo que não existem efeitos de substituição perfeita entre fatores de produção (Basher e Sadorsky, 2006)), o que, por sua vez, levará à diminuição dos seus níveis de lucros e *cash-flows* futuros (Filis *et al.*, 2011).

No canal de política monetária, as variações do preço do petróleo também afetam as taxas de desconto esperadas dos *cash-flows* futuros. Mohanty e Nandha (2011) consideram que a taxa de desconto é parcialmente constituída pela inflação esperada e pelas taxas de juros reais esperadas. Assim, o mecanismo de transmissão pelo qual as variações do petróleo afetam o mercado acionista dá-se através da inflação e das taxas de juro. O aumento do preço do petróleo resulta no aumento dos custos de produção, sendo estes transferidos para

⁵ Degiannakis *et al.*, (2018) referem ainda o canal de política fiscal, mas que apenas desempenha um papel efetivo nas economias exportadoras de petróleo.

os consumidores, levando ao aumento de preços no consumidor e ao aumento na inflação esperada (Hamilton, 1988, 1996). Em resposta ao aumento das pressões inflacionistas é esperado que as autoridades monetárias aumentem as taxas de juro de curto prazo (Basher e Sadorsky, 2006). O aumento das taxas de juro de curto prazo leva ao aumento do custo de financiamento dos investimentos futuros das empresas, o que, decorrente da diminuição dos *cash-flows*, levará à diminuição do número de projetos com valor atuais líquidos positivos. Assim, seja devido ao aumento das taxas de desconto ou à diminuição dos *cash-flows*, os preços das ações diminuem devido ao aumento do petróleo (Degiannakis *et al*, 2018).

A literatura sugere que as flutuações do petróleo afetam a produção agregada na economia (Kilian, 2008; Hamilton, 2009). Através do canal de produção agregada é esperado que aumentos no preço do petróleo exerçam, simultaneamente, um efeito de rendimento e de custo de produção, levando estes, por sua vez, a variações na produção agregada. O efeito no custo de produção foi enunciado no canal de avaliação de ativos empresariais. O efeito de rendimento resulta de os aumentos no preço do petróleo diminuírem o rendimento disponível das famílias, motivado pelas variações de preços no consumidor e, em particular, pelo aumento dos preços de bens de energia (gasolina, gásóleo, etc.). Por sua vez, um rendimento inferior leva a um menor consumo e produção agregada e a uma menor procura no mercado de trabalho. A estes desenvolvimentos, que tendem a ocorrer nas economias importadoras de petróleo, os mercados acionistas tendem a responder negativamente.

O canal de “incerteza”, proposto por Brown e Yucel (2002), propõe que o aumento do preço do petróleo leva ao aumento da incerteza na economia real, devido aos efeitos, entre outros, na inflação, produto agregado e consumo. Nesta linha, o aumento do preço do petróleo leva à diminuição da procura das empresas por investimentos irreversíveis, o que reduz os *cash-flows* e os lucros futuros esperados. Adicionalmente, a incerteza é também propagada às famílias que reduzem o consumo de bens duráveis (Pindyck, 2004; Edelstein e Kilian, 2009). Assim, o aumento da incerteza quanto ao preço futuro do petróleo leva à diminuição do incentivo ao investimento e ao consumo que, por sua vez, leva à diminuição das perspectivas de crescimento económico e do valor do mercado acionista.

2.2. Evidência empírica sobre a relação entre o preço do petróleo e o desempenho dos mercados acionistas

Os métodos econométricos e os dados utilizados na análise das relações entre o preço do petróleo e o desempenho dos mercados acionistas variam, dependendo do problema de investigação, das hipóteses a testar e se os investigadores utilizam como unidade de análise índices agregados dos mercados, índices sectoriais ou dados ao nível da empresa. Nas análises ao valor esperado da variável dependente e que utilizam dados agregados ou sectoriais, são frequentemente utilizados os modelos de Vetores Autoregressivos (VAR) (Sadorsky, 1999; Henriques e Sadorsky, 2008). Nos estudos que utilizam dados ao nível das empresas são utilizadas, frequentemente, as abordagens dos modelos de *Capital Asset Pricing* (CAPM) e de fatores de risco de mercado de Fama-French (1993), aos quais são acrescentadas as variações do preço do petróleo (Broadstock *et al.*, 2016; Phan *et al.*, 2015). Nos estudos que analisam a variação temporal da relação entre o preço do petróleo e o desempenho do mercado acionista, cujo interesse principal incide na variação temporal da variância condicional dos retornos, têm sido utilizados os modelos GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*), uni- e multivariados.

Os estudos empíricos que examinam o impacto do preço do petróleo nos índices acionistas agregados, tendem a sugerir uma relação negativa entre os dois mercados (Rahman, 2021; Miller & Ratti, 2009). Todavia, nesta linha de investigação, a literatura não é consensual quanto ao sinal, magnitude e significância da relação. A relação pode diferir consoante as características do país, do período amostral, pode variar ao longo do tempo e pode mesmo não haver nenhum impacto do petróleo nos mercados acionistas (Aloui & Jammazi, 2010)

Degiannakis *et al.* (2018) levaram a cabo uma revisão da evidência empírica sobre a relação entre os preços do petróleo e os mercados financeiros. Constatam que a maioria dos estudos incide sobre o impacto do preço do petróleo nos mercados financeiros, e em menor número estudos focados na relação inversa. A existência de relações, respetivos sinais e significância, tendem a depender do facto do correspondente mercado financeiro ser referente a países importadores ou exportadores líquidos de petróleo. Nos países exportadores de petróleo os mercados financeiros tendem a reagir positivamente a aumentos no preço do petróleo (Mokni, 2020; Aroui & Rault, 2012; Alshehri *et al.*, 2017; Sarwar *et al.*, 2018; Nusair & Al-khasawneh, 2018). No que concerne a variação de volatilidade e a correspondente transmissão de risco entre os mercados, a evidência sugere que, em geral, o aumento de volatilidade tende a ocorrer no mercado de energia, sendo depois transmitido aos mercados financeiros.

Ferreira *et al.* (2019) analisaram a relação entre o preço do petróleo e os mercados acionistas em 20 países nos períodos anterior e posterior à crise financeira global de 2007-2009. Os resultados sugerem que no período anterior à crise a maioria dos índices acionistas apresentavam uma correlação reduzida com o preço do petróleo, apesar de haver casos significativos. No período pós-crise a maioria dos países evidenciavam uma relação positiva e significativa.

Rahman & Serletis (2019) recorreram a um modelo VAR bivariado para examinar a relação entre variações do preço do petróleo e variações do mercado acionista dos EUA que, apesar de ser o maior produtor mundial de petróleo, só se tornou exportador líquido de petróleo em 2020⁶. Os resultados sugerem que variações positivas no preço do petróleo exercem efeitos negativos e significativos nos preços dos mercados acionistas. Esta relação tende a ser mais pronunciada em períodos de crise. No entanto, estes resultados não são observados quando o estudo incide sobre países exportadores líquidos de petróleo.

Nusair & Al-Khasawneh (2018) examinaram os efeitos das variações no preço do petróleo nos mercados financeiros dos países pertencentes ao Conselho de Cooperação do Golfo, em que o petróleo é considerado o principal propulsor da atividade económica e do qual as receitas fiscais estão significativamente dependentes. Os resultados sugerem que aumentos (diminuições) dos preços do petróleo exercem efeitos positivos (negativos) e significativos no mercado acionista quando este apresenta uma tendência de subida (descida), sugerindo co-movimentos positivos e significativos.

A análise ao nível agregado do mercado não revela os efeitos heterogéneos das respostas dos diferentes setores da atividade económica às alterações do preço do petróleo. A literatura evidência respostas heterogéneas consoante o setor industrial em estudo (Scholtens & Yurtsever, 2012). Numa análise setorial é possível separar os diferentes setores da economia segundo as suas características e detetar as respostas individuais de cada setor à variação do preço do petróleo. Nesta abordagem os resultados tendem a diferir consoante a dependência que cada setor tem do petróleo, podendo estes agruparem-se em setores utilizadores, sectores utilizadores de substitutos ou setores não utilizadores de petróleo. Os resultados sugerem que alterações no preço do petróleo tendem a ter um maior efeito nos setores dependentes do petróleo, tal como o setor dos transportes, da construção e indústria (Shaari, *et al.*, 2013).

Estudos que realizam análises setoriais sugerem que o setor energético, principalmente a indústria produtora de petróleo e gás, reage positivamente ao aumento do preço do

⁶ [Oil imports and exports - U.S. Energy Information Administration \(EIA\)](#)(2021)

petróleo. Setores como a saúde, alimentação, indústria transformadora e transportes, tendem a reagir negativamente (Selmi *et al.*, 2021; Bagirov & Mateus, 2019; Arouri & Nguyen, 2010; Lu & Paraco, 2018)

2.3. Relação entre choques no preço do petróleo e o mercado acionista

Em geral, na análise da relação entre a evolução do preço do petróleo e a evolução, entre outros, da produção agregada da economia e do mercado acionista, têm sido usados indistintamente os termos de “choques” e “variações” no preço do petróleo, medidos pelas primeiras diferenças dos logaritmos dos preços, não se atendendo ao racional económico de tais variações. Porém, dado que as variações de preços podem ter diferentes causas, vários estudos associam às variações dos preços do petróleo o racional económico que lhe está subjacente, inserindo nesta linha de investigação o conceito de “choques” no preço do petróleo (Barsky e Kilian, 2004; Kilian, 2008, 2009; Kilian e Park 2009).

Assim, os choques (*i.e.*, variações) no preço do petróleo são identificados e baseados nas fontes que causam tal variação. Em geral, um choque no preço do petróleo reflete uma variação no preço devido a uma variação não antecipada nos fundamentos do mercado petrolífero (*i.e.*, na oferta e procura global de petróleo). Kilian (2008, 2009) considera que podem ocorrer três tipos de choques no preço do petróleo: choques na oferta agregada, na procura agregada e na procura “preventiva”⁷.

Segundo estes estudos, os choques na oferta agregada estão relacionados com restrições na oferta, por exemplo, por parte dos principais países produtores, como estratégia para aumentar os preços. Por seu lado, eventos como agitações geopolíticas em algumas regiões produtoras de petróleo, não levam a choques no preço provocados por alterações na oferta agregada. Pelo contrário, os autores sugerem que estes eventos desencadeiam choques na procura preventiva, que resultam da incerteza que os eventos geopolíticos impõem aos agentes económicos acerca da disponibilidade futura de petróleo. Os autores consideram que os agentes económicos, ao esperarem uma escassez rápida na oferta após início da agitação geopolítica, aumentam de imediato a sua procura por petróleo, levando ao aumento do preço.

⁷ Tradução de: “precautionary demand”

Os choques na procura agregada estão relacionados com variações do preço do petróleo causadas por movimentos no ciclo económico global. Por exemplo, segundo os autores, o crescimento das grandes economias dependentes das energias fósseis, ao aumentar a procura por petróleo, mas não sendo esta acompanhada pelo correspondente aumento na oferta, leva ao aumento de preços. De igual modo, recessões económicas globais levam a reduções significativas na procura que, não sendo acompanhadas pela correspondente diminuição na oferta, levam à diminuição do preço. Neste âmbito, o argumento subjacente às proposições dos diferentes tipos de choques, como mecanismo para explicar os efeitos do petróleo no desempenho dos mercados financeiros, assenta no facto do preço do petróleo não ser necessariamente exógeno. Ou seja, podem ocorrer causalidades inversas, das variáveis macrofinanceiras para os preços do petróleo, e assim, o mercado de energia e os mercados financeiros serem influenciados pela atividade económica em geral.

Economou (2016) analisou as causas dos principais choques no preço do petróleo no período 1990-2015, constantes na Tabela 1. É possível observar que choques relacionados com a procura são predominantes e estão associados a períodos de expansão e contração económica. Choques que derivam de eventos geopolíticos são menos comuns.

Tabela 1: Variação do preço real do petróleo e principais fatores

Choque no preço do petróleo (Cronologia)	Fatores Chave
53% (Ago. 90 – Out. 90)	Guerra do Golfo; Choque na oferta agregada e procura preventiva
-57% (Dez. 97 – Dez 98)	Crise Financeira Asiática; Choque na procura agregada
77% (Jun 99 – Set. 00)	Forte crescimento industrial ao nível global; Cortes na oferta e forte procura agregada
13% (Dez. 02 – Mar. 03)	Crise venezuelana e guerra no Iraque; Choque na oferta agregada
145% (Jan. 03 – Jun. 08)	<i>Commodities supercycle</i> (Boom das <i>commodities</i>); Forte procura e oferta estagnada, choque na procura preventiva
-102% (Jul. 08 – Dez. 08)	Crise financeira global; Choque na procura agregada
35% (Dez. 10 – Abr. 11)	Primavera árabe; Choque na oferta
-73% (Jul. 14 – Jan. 15)	Excesso de capacidade; Forte oferta e procura estagnada, choque de procura preventiva

Fonte: adaptado de Economou (2016, p.4)

A característica comum dos choques é que todos afetam o preço do petróleo. No entanto, este efeito tem magnitudes e horizontes temporais diferentes. Segundo Kilian (2009) os aumentos do preço do petróleo produzem diferentes efeitos no preço real do petróleo

dependendo da causa subjacente. Um aumento na procura preventiva causa grandes aumentos no preço real do petróleo que são imediatos e persistentes; o aumento da procura agregada provoca o aumento substancial e persistente do preço real do petróleo e, por fim, as disrupções na produção de petróleo causam aumentos pequenos e progressivos no preço real do petróleo.

2.4. Relação entre o Ouro (como ativo de reserva de valor) e os mercados financeiros

O Ouro é dos metais preciosos mais populares e uma das *commodities* mais transacionadas. Este ativo constitui-se como ativo de reserva de valor porque, em geral, apresenta uma relação inversa com os mercados financeiros, sendo amplamente utilizado pelos investidores como instrumento de diversificação e cobertura de risco dos portefólios. O Ouro é um ativo que oferece proteção contra as pressões inflacionistas (Hoang *et al.*, 2016; Mccown & Zimmerman 2006) e tende a reagir de forma contra-cíclica a eventos macroeconómicos (Elder *et al.*, 2012). É um ativo que tende a manter o seu valor quando outros ativos o perdem, principalmente o mercado acionista. Por esta razão vários estudos consideram-no um ativo seguro para os investidores em períodos de incerteza (Baur & Lucey, 2010; Beckmann *et al.*, 2015). Todavia, os estudos que analisam as propriedades do Ouro, enquanto ativo de reserva de valor, não são unânimes, apresentando resultados diferentes consoante o período de análise, os métodos e os instrumentos utilizados.

Ming *et al.* (2020), num estudo relativo ao mercado chinês, consideram que o Ouro pode ser utilizado como instrumento de cobertura de risco apenas no longo prazo. Ghazali *et al.* (2020) consideram que o Ouro apresenta propriedades adequadas de cobertura de risco apenas em países desenvolvidos. Estes resultados são consistentes com os obtidos por Hussain Shahzad *et al.* (2020) que consideram que o Ouro se constitui como uma excelente ferramenta de cobertura de risco em relação aos índices bolsistas dos países do G7.

Porém, os resultados dos estudos que se focam no papel do Ouro em períodos de crise são variados. Abuzayed *et al.* (2022) refere que no Reino Unido o Ouro se apresentou como uma boa oportunidade de diversificação durante o *Brexit*. No entanto, face ao Ouro, o petróleo apresentou maior potencial de cobertura de risco.

Drake (2022) analisou os períodos da crise financeira global de 2007-2009 e a crise pandémica COVID-19, não obtendo evidências de uma correlação negativa entre o Ouro e os mercados acionistas, contrariando a crença de que os investidores se refugiam no Ouro

em períodos de *stress* económico. Constata, no entanto, que a relação entre o Ouro e os mercados financeiros é positiva em períodos com taxas de juro reais negativas e que o Ouro pode ser considerado um ativo seguro para os investidores em períodos de grande volatilidade nos mercados e de taxas de juro reais negativas, pois quando as taxas caem abaixo de zero os investidores movem as suas poupanças para os mercados do Ouro e financeiros. Os resultados de outros estudos sugerem que o Ouro revelou ser um ativo pouco seguro para os investidores durante a pandemia Covid-19, tendo apenas revelado propriedades de reserva de valor no período anterior à pandemia (Akhtaruzzaman *et al.*, 2021; Będowska-Sójka & Kliber, 2021; Chemkha *et al.*, 2021; Salisu *et al.*, 2021).

2.5. Relação entre a volatilidade dos mercados de *commodities* e dos mercados acionistas

2.5.1. Conceito de Volatilidade

A volatilidade, nos mercados financeiros e de *commodities*, é medida pelo parâmetro do desvio-padrão/variância da distribuição da taxa de variação do preço do ativo. É utilizada para quantificar o grau de variabilidade das taxas de variação do valor da série temporal e serve como medida de risco do ativo. Quando um ativo, face a outro, apresenta uma volatilidade superior significa que o nível de variabilidade das suas taxas de variação em torno do seu nível médio é superior ao observado no outro ativo.

A volatilidade pode ser analisada em duas perspetivas: na condicional e na não-condicional. Na análise da volatilidade condicional, esta é caracterizada pela estimação da relação funcional de dependência da variância, condicionada ao conjunto de informação disponível até ao período corrente. Assim, a variância condicional é variável no tempo e modelada segundo a relação de dependência especificada. Ao contrário, a variância não-condicional não tem subjacente uma relação de dependência, cada elemento da série histórica de observações tem idêntico peso no seu cálculo, é referida a um período amostral e assume-se constante e igual ao seu nível médio de médio/longo prazo.

Os modelos GARCH univariados são os modelos geralmente utilizados para modelar o comportamento, ao longo do tempo, da média e da volatilidade condicional da variável dependente. Estes modelos foram inicialmente desenvolvidos por Engle (1982) e posteriormente generalizados por Bollerslev *et al.* (1986). Estes, na sua forma genérica, são

compostos por duas funções: a) função da média condicional e a b) função da variância condicional da variável dependente. A especificação do modelo é a seguinte:

$$y_t = \phi(\theta)_t + \varepsilon_t \quad (2)$$

onde y_t representa a variável dependente cuja variância se pretende modelar, $\phi(\theta)_t$ representa a relação funcional do valor esperado da variável dependente e θ o conjunto de parâmetros a estimar desta função. A equação da variância condicional de y_t , *i.e.* de ε_t , é especificada como:

$$\sigma_t^2 = \alpha_0 + \sum_{j=1}^q \alpha_j \varepsilon_{t-j}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (3)$$

onde as seguintes condições devem ser observadas: $\alpha_0 \geq 0$, $\alpha_j \geq 0$, $\beta_j \geq 0$. Para que o processo autorregressivo do modelo seja estacionário é necessário que se verifique a condição: $\sum_{j=1}^q \alpha_j + \sum_{j=1}^p \beta_j < 1$. Neste modelo, a volatilidade condicional atual (*i.e.*, σ_t^2) é explicada pela taxa de variância de longo prazo, α_0 (*i.e.*, variância não-condicional), pelo quadrado dos resíduos anteriores, ε_{t-j}^2 , e pelos valores anteriores estimados da volatilidade condicional, σ_{t-j}^2 . Ou seja, a volatilidade condicional no período corrente é uma média ponderada das medidas de volatilidade condicionais e do quadrado dos erros anteriores.

Posteriormente, com o objetivo de modelar simultaneamente as volatilidades condicionais individuais, os co-movimentos e os efeitos de transmissão de volatilidade entre os mercados, foram desenvolvidas vários modelos GARCH multivariados, dos quais se destacam: GARCH-VECH (Bollerslev *et al.*, 1988); GARCH-BEKK (Engle and Kroner, 1995), GARCH-CCC (*i.e.*, correlação condicional constante) (Bollerslev, 1990) e DCC (*i.e.*, correlação condicional dinâmica) (Engle, 2002).

Outros estudos, na análise das relações entre as volatilidades dos mercados, recorrem também ao índice *spillover* e de conectividade de Diebold & Yilmaz (2012) que combina a previsão do erro da decomposição da variância com o modelo VAR. Os modelos acima referidos são utilizados no estudo do efeito *spillover* (*i.e.*, de transmissão) de volatilidade e de co-movimentos, permitindo estudar os efeitos de transmissão de risco entre diferentes mercados. Permitem analisar se a volatilidade ocorrida num mercado num período anterior afeta o nível de volatilidade noutro mercado no período corrente. Sendo frequente a utilização de processos autorregressivos na modelização do valor esperado da variável dependente. Estes modelos permitem também estudar o efeito *spillover* da variação do preço de um ativo na variação dos preços de outros ativos, aparentemente não relacionados.

Quando nos referimos ao efeito *spillover* estamos a falar de efeitos de transmissão de informação e/ou de risco. É importante referir que existem vários tipos de efeitos *spillover*.

Nos *spillovers* de volatilidade (estudados normalmente recorrendo a modelos GARCH multivariados) temos o *spillover* de volatilidade própria, em que se testam os efeitos da volatilidade corrente de uma variável no valor da sua volatilidade no futuro e o *spillover* de volatilidade cruzada, em que se testam os efeitos da volatilidade de uma variável no período corrente na volatilidade de outra variável no período seguinte. Temos ainda o efeito *spillover* de retornos, normalmente analisado recorrendo aos coeficientes do modelo VAR, em que são estimados os coeficientes nas equações do modelo VAR para medir o nível de dependência dos retornos de uma variável com os retornos passados de outras variáveis.

Como a análise do comportamento e das interdependências dos mercados financeiros, ao nível do primeiro e segundo momentos da distribuição da taxa de variação dos preços, é crucial para o processo de tomada de decisão, seja na perspetiva dos agentes económicos, em geral, seja dos investidores individuais e institucionais e das autoridades de coordenação e regulação dos mercados, em particular, reveste-se de importância investigar os efeitos *spillover* nos mercados financeiros e de *commodities*.

2.5.2. Evidência empírica dos efeitos *spillover* entre mercados acionistas e mercados de *commodities* (petróleo e Ouro).

Balcilar *et al.*, (2021) examinam os efeitos *spillover* de volatilidade e de retornos entre o índice S&P500, o petróleo e o Ouro, recorrendo ao índice de *spillover* de Diebold e Yilmaz (2012). A análise mostra que o índice S&P 500 e o petróleo são emissores líquidos enquanto o Ouro é recetor líquido de *spillover* de retornos. No que concerne o *spillover* de volatilidade, o S&P 500 e o Ouro revelam-se emissores líquidos enquanto o petróleo é recetor líquido.

Liu *et al.*, (2017) recorreram ao modelo VAR-GARCH-BEKK multivariado para explorar os efeitos *spillover* de volatilidade e de retornos entre o mercado de petróleo e os mercados acionistas dos EUA e da China. Os resultados indicam que entre o mercado acionista americano e o mercado do petróleo existem *spillovers* de retornos bi-direcionais. Quanto ao efeito *spillover* de volatilidade este revela-se uni-direcional, do mercado do petróleo para o mercado acionista. Entre o mercado acionista chinês e o mercado do petróleo existem efeitos *spillovers* de retornos do mercado do petróleo para o acionista, não existindo, todavia, evidência de efeitos *spillover* de volatilidade.

Thuraisamy *et al.*, (2013) recorreram ao modelo bi-variado BEKK-GARCH para testar os efeitos *spillover* de volatilidade entre 14 mercados acionistas asiáticos e a volatilidade dos preços de futuros do petróleo e do Ouro. Os resultados variam de acordo com o nível de

desenvolvimento dos mercados. Os resultados mostram que para os mercados desenvolvidos, os efeitos *spillover* manifestam-se destes para os mercados de futuros do petróleo e do Ouro. No caso dos mercados acionistas menos desenvolvidos o efeito *spillover* manifesta-se do mercado de *commodities* para o mercado acionista.

Zhang *et al.* (2021) utilizam os modelos multivariados VAR-CCC-GARCH e VAR-DCC-MGARCH para examinar o efeito *spillover* de volatilidade entre o mercado acionista chinês, o mercado obrigacionista e os mercados de futuros do Ouro e do petróleo. Os resultados indicam que não existem efeitos *spillovers* significativos do Ouro para os mercados acionista e obrigacionista; existe, no entanto, um efeito *spillover* bidirecional entre o Ouro e o petróleo.

Maghyereh *et al.*, (2017) analisam, através do modelo multivariado DCC-MGARCH, os efeitos *spillovers* de retornos e de volatilidade entre os mercados acionistas, o petróleo e o Ouro nos países pertencentes ao Conselho de Cooperação do Golfo. Os resultados evidenciam efeitos *spillovers* significativos dos retornos e da volatilidade do petróleo para as ações, devido à elevada dependência que estes países têm das receitas do petróleo. Por sua vez, não existem efeitos *spillovers* significativos do Ouro para o mercado acionista e este não exerce influência no mercado de *commodities*. Porém, existem efeitos *spillover* bidirecionais dos retornos e da volatilidade entre o Ouro e o petróleo.

Mensi *et al.*, (2013) analisam a correlação e o efeito *spillover* de volatilidade entre o mercado acionista norte-americano (S&P500) e o mercado de *commodities* (energia, alimentação e Ouro) utilizando o modelo multivariado VAR-CCC-GARCH. Os resultados obtidos indicam que a transmissão de volatilidade entre o S&P500 e o mercado de *commodities* é significativa e que os retornos não-esperados e a volatilidade prévia do S&P500 influenciam os mercados do petróleo e do Ouro.

Morema e Bonga-Bonga (2020) estudam os efeitos *spillover* de volatilidade entre os mercados do petróleo, do Ouro e o mercado acionista sul-africano, recorrendo ao modelo VAR-ADCC-MGARCH. A evidência empírica sugere que existem efeitos *spillover* de volatilidade unidirecionais do mercado do Ouro para o mercado acionista e do mercado do petróleo para o mercado acionista.

Kang *et al.*, (2021) analisam os efeitos *spillover* de volatilidade entre os ETF's (*Exchange Traded Funds*) setoriais norte-americanos e os mercados do petróleo e do Ouro. A evidência sugere que o petróleo exerce um maior efeito que o Ouro nos ETF's setoriais, tanto no curto como no longo prazo. Os resultados mostram ainda que os efeitos *spillovers* entre os ETF's setoriais, o petróleo e o Ouro são assimétricos no curto e no longo prazo, sendo mais fortes

no curto prazo e aumentando consideravelmente em períodos de turbulência e incerteza económica.

2.6. Relações entre mercados financeiros e mercados de *commodities* durante as crises financeiras

2.6.1. A crise pandémica Covid-19 e o aumento do risco nos mercados

A pandemia Covid-19 é uma crise sanitária que teve, e continua a ter, impactos significativos na economia mundial. Neste contexto torna-se importante analisar as interdependências entre os mercados financeiros e de *commodities* que proporcionem, respetivamente, aos decisores políticos e aos investidores, em geral, um quadro de avaliação sobre as medidas necessárias e adequadas de política económica e de regulação, e sobre as implicações em termos de decisões de investimento e redução de risco dos portefólios.

A incerteza gerada pela pandemia e as perdas económicas associadas tornaram os mercados voláteis e imprevisíveis. Rehman *et al.* (2021) examinaram os co-movimentos entre os mercados financeiros dos países do G7 e os números de casos e de mortes relacionadas com a doença COVID-19. Os resultados demonstram que, em geral, existe uma relação significativa entre aumento de volatilidade e aumento de mortes, sendo que esta tende a ser mais pronunciada no longo do que no curto prazo.

A literatura recente evidencia uma forte causalidade entre a intensidade da doença COVID-19 e o aumento do risco nos mercados. Liu *et al.* (2022) analisaram a propagação do risco financeiro em 16 mercados acionistas durante a pandemia. Constataram que, após o seu início, a integração internacional dos mercados acionistas aumentou consideravelmente. Entende-se por integração o aumento da sincronização entre os co-movimentos dos mercados, tendo esta sido também acompanhada pelo correspondente aumento significativo na propagação do risco entre mercados.

A volatilidade nos mercados durante este período está diretamente relacionada com o nível de propagação do vírus. Albuлесcu (2021) investigou os efeitos que os anúncios oficiais da doença COVID-19, de novos casos de infeção e de mortes, tiveram na volatilidade dos mercados financeiros dos EUA. Os resultados sugerem que os anúncios oficiais tiveram um impacto positivo e significativo na volatilidade dos mercados financeiros. Estes resultados estão em linha com os obtidos por Zhang *et al.* (2020). Estes autores levaram a cabo uma

análise ao impacto da pandemia no risco dos mercados financeiros nos 10 países com mais casos confirmados de infeção pelo vírus. Os resultados sugerem que, em geral, o risco dos mercados financeiros aumentou e que a reação individual de cada mercado está claramente relacionada com a severidade e o nível de propagação do vírus no país.

2.6.2. Breve descrição da crise financeira global (2007-2009) e da crise da dívida soberana (2010-2013).

A crise financeira global de 2007-2009 é considerada uma das mais longas e mais significantes crises económicas (Bordo & Haubrich, 2017). Começou em 2007, com uma crise no mercado hipotecário de *subprime* nos Estados Unidos, e a sua gravidade aumentou exponencialmente com o colapso do gigante da banca Lehman Brothers em setembro de 2008. A crise do *subprime* foi seguida por um período de abrandamento no crescimento económico global que ficou conhecido como a grande recessão. Vários fatores contribuíram para esta crise financeira, nomeadamente o aumento da dívida, devido à introdução de novos instrumentos financeiros complexos, o aparecimento de uma bolha imobiliária, irresponsabilidade na gestão do risco e falhas na regulação do mercado (Hausman & Johnston, 2014). Este período caracteriza-se por ter provocado uma diminuição e/ou abrandamento do crescimento económico em países industrializados, taxas de desemprego elevadas e persistentes, grandes défices públicos e correspondentes dívidas, redução da taxa de inflação e taxas de juro muito baixas.

O período da crise financeira global foi sucedido pela crise da dívida soberana. Esta última acabou por ser uma crise que durou vários anos e que já se vinha a formar desde o fim de 2009, período em que países como Grécia, Irlanda, Itália, Portugal e Espanha, tiveram dificuldades em pagar ou refinarciar as suas dívidas, e revelaram-se incapazes de resgatar as suas instituições bancárias afundadas em dívidas sem ajuda externa. A incapacidade destes países em pagar as suas dívidas levou à perda de confiança dos investidores, foi necessária ajuda externa para estes países não entrarem em incumprimento, seguida de períodos de austeridade.

2.6.3. Evidencia empírica dos efeitos *spillovers* entre mercados acionistas e de *commodities* durante períodos de crises económico-financeiras

A literatura sobre a existência de *spillovers* entre os mercados financeiros e os mercados de *commodities* durante o período da pandemia COVID-19 ainda é escassa. Porém, analisando a literatura que incide sobre crises financeiras anteriores, é possível observar que os *spillovers* tendem a ser mais acentuados em períodos de crise e que, por vezes, crises anteriores têm influência no surgimento de crises posteriores.

Kang e Yoon (2019) analisam as dinâmicas de *spillovers* de volatilidade entre o mercado acionista chinês e quatro *commodities* (alumínio, cobre, petróleo e borracha natural), aplicando o modelo DECO-GARCH (Dynamic equicorrelation-GARCH) multivariado e o índice de *spillover* Diebold & Yilmaz (2012) durante os períodos da crise financeira global de 2007-2009 e da crise da dívida soberana europeia (2010-2013). Os resultados evidenciam uma equi-correlação positiva entre o mercado acionista e as quatro *commodities* na crise da dívida soberana. Mostram também que os efeitos *spillovers* de volatilidade são bi-direcionais e que as tendências de *spillovers* são mais pronunciadas durante a crise da dívida soberana, o que sugere uma forte influência da crise financeira global de 2007-2009.

Mensi *et al.*, (2021) abordaram os efeitos da crise pandémica Covid-19, recorrendo ao modelo *Markov-switching VAR* para analisar os *spillovers* existentes entre os mercados acionistas norte-americano e chinês e as variações dos preços de futuros do petróleo e do Ouro durante a pandemia Covid-19, em regimes de elevada e de baixa volatilidade. Os resultados mostram que o Ouro e os mercados acionistas são emissores (recetores) líquidos de *spillovers* no regime de baixa (alta) volatilidade, enquanto o petróleo foi um dos principais recetores (emissores) de *spillovers* no regime de baixa (alta) volatilidade. Em geral, o estudo concluiu que a pandemia Covid-19 intensificou os *spillovers* dos mercados de *commodities* para os mercados acionistas.

Hung & Vo (2021) analisaram os efeitos *spillovers* e as interdependências entre o índice S&P500, o petróleo e o Ouro, recorrendo a um índice de *spillover* e ao método de Coerência de Onda (*wavelet coherence*), de forma a estimar e medir a relação que os valores prévios de uma variável produzem nos valores futuros de outra variável, durante o período pré-Covid-19 e o período Covid-19. Os resultados revelam que os *spillovers* são mais pronunciados no período Covid-19. Todavia, o S&P500 e o petróleo são recetores líquidos de risco enquanto o Ouro se revela como emissor líquido de risco no período pre-Covid-19, em contraste com o período Covid-19 em que o S&P500 e o petróleo são transmissores de *spillovers* de retornos.

A crise financeira global de 2007-2009 e o período de pandemia Covid-19 apresentam padrões de transmissão de risco diferentes. Laborda & Olmo (2021) examinaram a transmissão de risco entre sete setores econômicos no mercado acionista norte-americano utilizando o índice de Diebold & Yilmaz (2012). Os resultados sugerem que foi nos setores da banca & seguros, da energia, da tecnologia e da biotecnologia que tiveram origem os efeitos *spillover* de volatilidade e daqui se propagaram para o resto da economia. Durante a crise financeira global de 2007-2009 (a crise do Covid-19) os setores da banca & seguros (os setores energético e tecnológico) foram os mais relevantes.

Jebabli *et al.* (2021) levaram também a cabo uma análise comparativa dos *spillovers* de volatilidade entre o mercado de energia e os mercados acionistas durante os períodos da crise financeira global de 2007-2009 e da crise pandêmica Covid-19. Recorreram a índices acionistas globais, constituídos por ações representativas dos principais mercados acionistas mundiais, e aos futuros do petróleo Brent e do gás natural, para representar o mercado energético, tendo obtido os seguintes resultados. Primeiro, os *spillovers* de volatilidade entre os mercados durante a crise da pandemia Covid-19 excederam os registados durante a crise financeira de 2007-2009. Segundo, durante a crise financeira global de 2007-2009 os mercados acionistas foram emissores líquidos de volatilidade para os mercados de energia. Assim, a crise pandêmica revelou ter maiores impactos no *spillover* de volatilidade do que a crise financeira global.

Li *et al.* (2021) examinaram os impactos da crise financeira global de 2007-2009 e da crise pandêmica Covid-19 nas variáveis macro da economia norte-americana. Os resultados confirmam que a atual crise pandêmica Covid-19 demonstra ser mais severa, em termos de atividade econômica, do que a experienciada durante a crise financeira global. Todavia, a atual crise pandêmica revela ter menores probabilidades de efeitos recessivos do que a crise financeira global de 2007-2009.

Zhang & Hamori (2021) analisaram os efeitos *spillover* de volatilidade e dos retornos, durante o período da pandemia Covid-19, entre o mercado do petróleo e os mercados acionistas dos EUA, Japão e Alemanha recorrendo ao índice de *spillover* Diebold & Yilmaz (2012) e ao método de Barunik & Krehlik (2018), que utiliza a transformação de Fourier para transformar os resultados do modelo de Diebold & Yilmaz (2012) num método baseado nas dinâmicas da frequência. Os resultados indicam que o *spillover* de retornos ocorre principalmente no curto prazo e o *spillover* de volatilidade no longo prazo. Constatam ainda que os impactos da Covid-19 na volatilidade do petróleo e dos mercados acionistas foram superiores aos observados durante a crise financeira global de 2007-2009.

Thuraisamy *et al.*, (2013) recorreram ao modelo bi-variado BEKK-GARCH para estudar as interações de volatilidade entre 14 mercados acionistas de países asiáticos e a volatilidade dos futuros do petróleo e o Ouro. Os resultados indicam que a maioria das interações de volatilidade entre os futuros do petróleo e os mercados acionistas ocorreram durante o período da crise financeira global de 2007-2009. No que concerne a transmissão de volatilidade entre os futuros do Ouro e os mercados acionistas esta ocorreu maioritariamente durante o período pré-crise. Ou seja, a transmissão de volatilidade do preço do petróleo para os mercados acionistas foi dominante durante o período da crise financeira global 2007-2009, enquanto a transmissão de volatilidade do preço do Ouro para os mercados acionistas teve maior significância no período pré-crise. Estes resultados indicam que os impactos da volatilidade do Ouro e do petróleo na volatilidade dos mercados acionistas são heterogêneos.

Liao *et al.*, (2021) utilizaram os principais índices acionistas de 16 países, juntamente com as cotações de fecho do Ouro e do petróleo e o índice de *spillover* de Diebold & Yilmaz (2014) para estudar os efeitos *spillover* em períodos de choques sanitários (*i.e.*, períodos em que existem situações de emergência de saúde pública). A evidência mostra que os efeitos *spillover* de retornos e de volatilidade entre os diversos ativos são significativos, sendo o *spillover* de retornos o mais estável e o *spillover* de volatilidade muito sensível a choques relacionados com emergências de saúde pública. As maiores intensidades de *spillovers* foram observadas durante o período da Covid-19. O choque provocado pelo Covid-19 alterou as características do mercado, tornando o mercado do Ouro um recetor de risco, deixando o Ouro de ser considerado um ativo mais seguro em períodos de incerteza.

Yaya *et al.*, (2016) investigaram a persistência de volatilidade e o *spillover* de retornos entre as cotações de fecho do petróleo e do Ouro no período anterior e posterior à crise financeira global de 2007-2009. Os resultados indicam que, tanto no período anterior como posterior à crise, a volatilidade no mercado do Ouro foi inferior à volatilidade no mercado do petróleo. A análise empírica indica ainda que existem efeitos bidirecionais de *spillover* de retornos no período anterior à crise, e efeitos unidirecionais, do Ouro para o petróleo, após a crise.

Mensi *et al.*, (2022) testaram as assimetrias no *spillover* de retornos entre os futuros do Ouro e do petróleo e 22 índices setoriais europeus, recorrendo ao índice de *spillover* de Diebold & Yilmaz (2012). Os autores dividem os dados em 3 sub-amostras: uma com os retornos agregados, outra baseada apenas nos retornos negativos e outra com os retornos positivos. Os resultados mostram que o Ouro e o petróleo são recetores líquidos de *spillovers* de retornos enquanto a maioria dos índices setoriais são emissores líquidos de *spillovers* de retornos. A análise comparativa entre a amostra com retornos positivos e a

amostra com retornos negativos revela que o *spillover* total é superior na amostra com retornos negativos, implicando efeitos assimétricos na transmissão de volatilidade.

Chang *et. al.*, (2019) recorreram ao BEKK diagonal para analisar o *spillover* de volatilidade entre o petróleo e os mercados financeiros dos EUA, Reino Unido e China, no período anterior à crise financeira global 2007-2009, durante e pós-crise financeira global. Foram utilizados os preços *spot* e de futuros do petróleo WTI e Brent, bem como os preços *spot* e de futuros dos principais índices de cada país. Os resultados revelam que para os mercados americano e britânico existem efeitos de *spillover* de volatilidade negativos e significativos para qualquer par de crude e índice financeiro durante a crise e pós-crise, enquanto no período pré-crise e no período completo a maioria dos pares apresentava sinais diferentes de efeitos de volatilidade.

3. Dados e Metodologia

3.1. Dados

Para alcançar os objetivos estabelecidos para o presente estudo foram recolhidas as cotações de fecho diárias dos principais índices acionistas dos mercados do G7 e da China, representados pelos índices CAC40 (França), CSI300 (China), DAX30 (Alemanha), FTSE100 (Reino Unido), MIB (Itália), NIKKEI (Japão), TSX (Canadá) e S&P500 (Estados Unidos). Foram também recolhidas as cotações de fecho diárias dos contratos de futuros para o Ouro, Brent e WTI (*west texas intermediate*). As cotações dos índices foram recolhidas na sua moeda base e posteriormente convertidas para dólares. As cotações das *commodities* foram originalmente obtidas em dólares e são medidas em dólares por onça, no caso do Ouro, e dólares por barril, no caso do WTI e do Brent. Todos os dados foram recolhidos recorrendo a um terminal *Bloomberg* de forma a obter dados fidedignos e com a melhor qualidade possível.

Existem ligeiras diferenças entre os dias em que os mercados estão simultaneamente abertos ao longo do ano, especialmente no que diz respeito aos feriados que podem diferir de país para país. Para contornar este problema considerámos apenas os dias em os mercados estão simultaneamente abertos nos oito países em estudo, excluindo da amostra os dias em que pelo menos um mercado de um país está encerrado.

O período de análise amostral compreende o período que vai de 26/07/2007 até 31/12/2021. De forma a considerar no estudo os três períodos de crise, o período amostral foi dividido em 3 sub-períodos que correspondem ao período da crise financeira global 2007-2009, ao período da crise da dívida soberana e ao período da crise Covid-19.

Para estudar o período da crise financeira global iremos considerar o período que compreende a crise do *sub-prime* e o período de recessão que se seguiu. De acordo com Fry-McKibbin *et al.* (2014) o começo da crise do *sub-prime* coincide com o aumento da aversão ao risco e da queda de liquidez que surgiram em 26 de julho de 2007 até 14 de setembro de 2008, e o período de recessão corresponde à janela temporal de 15 de setembro de 2008 até 31 de dezembro de 2009. Assim, o período considerado para a crise financeira global 2007-2009 será de 26/07/2007 até 31/12/2009 (T=636). O período correspondente ao período da crise da dívida soberana será de 01/01/2010 até 31/12/2013 (T=1043). O período correspondente à crise Covid-19 será considerado a partir do dia seguinte a 30 de dezembro de 2019, que corresponde ao primeiro caso de Covid-19 anunciado pela organização

mundial de saúde na China até ao final de 2021 pois é o período mais recente para o qual estão disponíveis dados. Assim, o período da crise do Covid-19 é definido pelo período de 31/12/2019 até 31/12/2021 ($T=524$).

As figuras 1, 2 e 3 apresentam, respetivamente, a evolução dos valores, sobrepostos, dos logaritmos das séries dos índices acionistas, do petróleo e do Ouro, para as três crises financeiras consideradas no estudo. É possível observar que em todos os sub-períodos analisados o aumento de volatilidade tende a ocorrer em simultâneo em todas as séries consideradas no estudo.

Na crise financeira global, a partir do final do terceiro quadrimestre de 2008 e até ao segundo quadrimestre de 2009, todas as séries apresentam uma tendência de queda, com a exceção do Ouro que retém o seu valor e até aumenta em alguns casos. No caso da dívida soberana, os co-movimentos nos níveis das séries não é tão perceptível. Porém, é perceptível que no terceiro quadrimestre de 2011 as séries tendem a evidenciar um co-movimento de queda, com exceção do NIKKEI e do Brent que se mantêm relativamente estáveis e do Ouro que consegue ganhar algum valor. Por último, no período da crise do Covid-19, é possível observar que no final do primeiro quadrimestre de 2020 todas as séries apresentam uma ligeira queda momentânea, seguida de uma recuperação, com a exceção do Brent e do WTI que evidenciam uma queda mais acentuada, que se estendeu pelo segundo quadrimestre de 2020, seguida de uma recuperação. É importante realçar que no dia 20 de abril de 2020 os futuros do WTI ficaram negativos. No entanto, de forma a proceder à logaritmização da série, que não permite números negativos, esse valor foi removido.

Figura 1: Evolução dos índices acionistas do G7 e da China, do petróleo e do Ouro durante a crise financeira global (unidade.: logaritmo da série)




Figura 2: Evolução dos índices acionistas do G7 e da China, do petróleo e do Ouro durante a crise da dívida soberana (unidade.: Logaritmo da série)

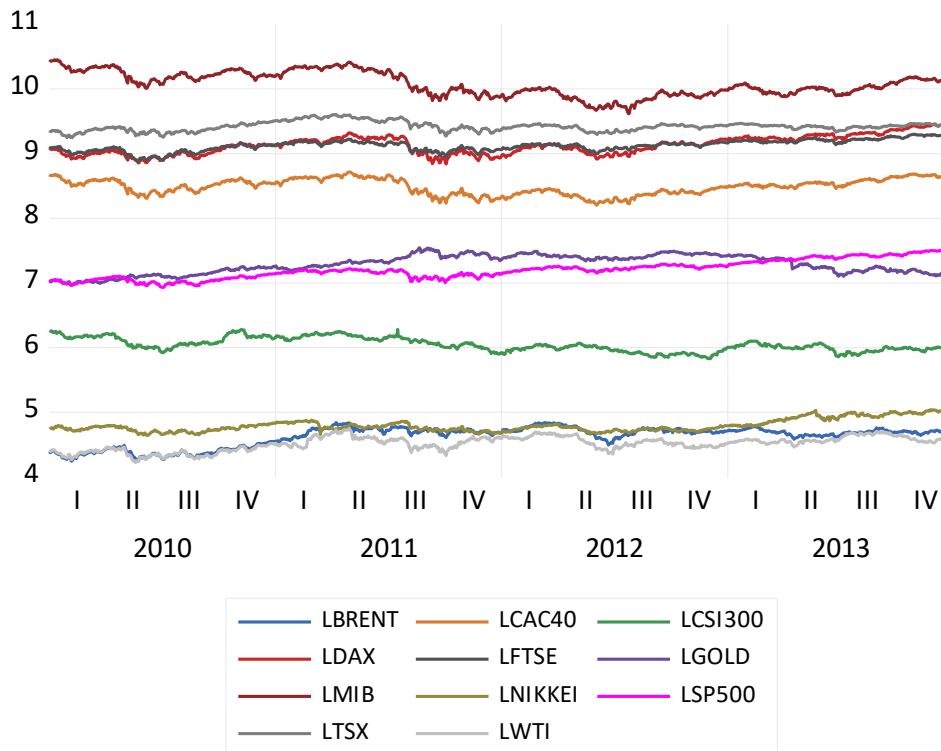
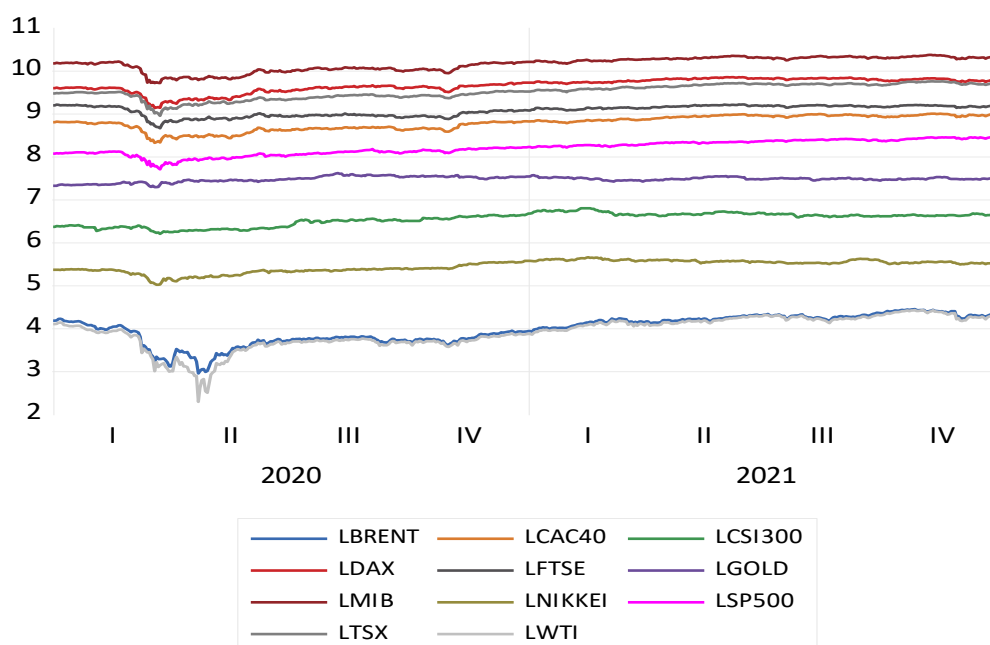


Figura 3: Evolução dos índices acionistas do G7 e da China, do petróleo e do Ouro durante a crise da Covid-19 (unidade.: Logaritmo da série)



Os retornos diários de cada série foram calculados, em percentagem, através da fórmula:

$$r_t = 100 * (\ln P_t - \ln P_{t-1}) \quad (4)$$

onde P_t corresponde à cotação de fecho do mercado no período t.

3.2. Testes de raízes unitárias e de cointegração

A estacionariedade é um conceito importante na análise de séries temporais, assumindo uma importância crucial na interpretação dos modelos e nos procedimentos de inferência dos parâmetros. Numa variável estacionária, as suas propriedades estatísticas não se alteram ao longo do tempo, ou seja, a sua média, a variância e a co-variância são constantes ao longo do tempo. De forma simplificada, uma variável estacionária reverte para a sua média enquanto uma não-estacionária diverge da média não-condicional ao longo do tempo.

Para avaliar a estacionariedade de uma série temporal é necessário analisar a presença de raiz unitária na série. Uma série, representada como um processo estocástico linear, tem uma raiz unitária se 1 é raiz da equação característica do processo. Assim, uma variável estacionária (não-estacionária) não contém (contém) uma raiz unitária, no seu processo autorregressivo. Os testes mais comuns para a deteção de raízes unitárias são o teste *Dickey-Fuller* (DF), o teste *Augmented Dickey-Fuller* (ADF) e o teste *Philips-Perron* (PP) (Dickey

e Fuller, 1979; Said e Dickey 1984; Phillips and Perron, 1988). O teste DF é baseado num modelo autorregressivo de primeira ordem, $AR(1)$, e tem como hipótese nula a existência de raiz unitária. No entanto, a utilização deste teste pode levar a um problema de autocorrelação. Por esta razão foi desenvolvido o teste ADF que tem como base o teste DF, mas que é baseado numa estrutura de um modelo autorregressivo de médias móveis, $ARMA(p,q)$, com a mesma hipótese nula. O teste PP é uma generalização do teste ADF em que os termos de perturbação estão correlacionados em série, introduzindo um termo de correção à estatística obtida no teste ADF. A hipótese nula deste teste é a série apresentar uma raiz unitária, ou seja, ser não-estacionária.

O modelo de regressão clássico assume que as variáveis dependente e independentes são estacionárias ao longo do tempo. No entanto, a maior parte das variáveis económicas apenas se tornam estacionárias após serem diferenciadas. Se o método de regressão clássico for aplicado às variáveis em nível não-estacionárias, este procedimento pode levar à ocorrência de uma relação espúria.

De forma a considerar as características de não estacionariedade das variáveis nos modelos de regressão e examinar a ocorrência de uma efectiva relação de equilíbrio de longo prazo tendem a ser utilizados procedimentos e os correspondentes testes de cointegração. Este conceito refere que, considerando num modelo de regressão séries individuais não estacionárias, em geral séries integradas de ordem 1, $I(1)$, se a série dos resíduos da regressão estimada, assumida esta como uma combinação linear de séries $I(1)$, for estacionária, então a regressão não é espúria e a regressão evidencia um racional económico em termos de relações de equilíbrio de médio/longo prazo. Enquanto na teoria económica conseguimos agregar variáveis na mesma teoria, nos trabalhos empíricos essa relação é evidenciada através da análise da cointegração. Se as variáveis forem cointegradas então existe uma relação linear, estável e de longo prazo entre as variáveis. As duas formas mais comuns de testar a presença de cointegração é através do teste de Engle e Granger (1987) e o teste de Johansen (1988).

No presente trabalho são utilizados o teste *Augmented* Dickey-Fuller e o teste Philips-Perron para testar a estacionariedade das séries. Para testar a ocorrência de cointegração entre as séries nos vários modelos estimados é utilizado o teste de cointegração de Johansen, no qual os testes de traço e de máximo autovalor são utilizados para verificar a presença de cointegração. A hipótese nula do teste é a não existência de cointegração. Caso o conjunto de variáveis a ser testado evidencie um ou mais vetores de cointegração, para modelar as equações da média condicional da variável dependente utilizamos o *Vector Error Correction Model* (VECM), que se ajusta a mudanças de curto prazo e a desvios do equilíbrio nas variáveis. Caso contrário será utilizado o modelo de Vectores Autoregressivos

(VAR) que, sendo também num modelo multivariado, permite relacionar as observações atuais de uma variável em função das observações passadas, próprias e das outras variáveis no sistema.

3.3. Modelos multivariados de Heteroscedasticidade Condicional Autorregressiva

Considerando que os dois modelos multivariados de heteroscedasticidade condicional autorregressiva, o modelo BEKK-diagonal e o modelo de Correlação Condicional Dinâmica (DCC-MGARCH), são considerados os mais adequados para examinar as relações de interdependências, de transmissão de risco e os co-movimentos entre mercados financeiros e de *commodities*, sendo frequente a sua utilização na literatura empírica nesta área de investigação, apresentam-se a seguir os seus fundamentos teóricos e respetiva interpretação.

Considere-se o processo estocástico vetorial $\{y_t\}_{t=1}^T$, de ordem $(N \times 1)$, cujos valores são condicionais ao conjunto de informação I_{t-1} , gerado pela informação prévia, *i.e.*, pela série de y_t até ao período $t - 1$. Denotamos θ como o vetor finito dos parâmetros da função da média condicional e especificamos o modelo como (Bauwens *et al.*, 2006):

$$y_t = \mu_t(\theta) + \varepsilon_t \quad (5)$$

onde $\mu_t(\theta)$ representa o vetor da função da média condicional e

$$\varepsilon_t = H_t^{\frac{1}{2}}(\theta)z_t \quad (6)$$

onde $H_t^{\frac{1}{2}}(\theta)$ é uma matriz definida positiva $(N \times N)$. Adicionalmente assumimos que o vetor aleatório z_t apresenta os seguintes dois primeiros momentos:

$$E(z_t) = 0 \quad (7)$$

$$Var(z_t) = I_N \quad (8)$$

onde I_N é a matriz identidade de ordem N . A matriz de variância condicional de y_t vem:

$$\begin{aligned} Var(y_t|I_{t-1}) &= Var_{t-1}(y_t) = Var_{t-1}(\varepsilon_t) \\ &= H_t^{\frac{1}{2}}Var_{t-1}(z_t)\left(H_t^{\frac{1}{2}}\right)' = H_t \end{aligned} \quad (9)$$

onde $H_t^{\frac{1}{2}}$ é qualquer matriz definida positiva ($N \times N$) tal que H_t é a matriz de variância condicional de y_t , *i.e.*, $H_t^{\frac{1}{2}}$ pode ser obtida pela factorização de Cholesky de H_t . Ambos H_t e μ_t dependem do vetor dos parâmetros desconhecidos θ , que pode, na maior parte dos casos, ser decomposto em duas partes disjuntas, uma para μ_t e outra para H_t . A equação da média condicional é geralmente especificada como função dos valores prévios de y_t , por exemplo, através de um processo VAR ou VECM.

A seguir apresentam-se as duas especificações multivariadas da matriz H_t que utilizamos na presente dissertação: i) o modelo BEKK-Diagonal-GARCH e ii) o modelo GARCH de Correlação Condicional Dinâmica, DCC – GARCH.

3.3.1. Modelo BEKK-Diagonal – GARCH

No presente estudo, na análise dos efeitos de transmissão de risco entre o mercado de *commodities* e os mercados financeiros nacionais, é utilizado o modelo BEKK-Diagonal-GARCH. Este modelo, inicialmente proposto por Baba et al. (1990) e posteriormente desenvolvido por Engle e Kroner (1995), foi motivado pela dificuldade em garantir a positividade da matriz H_t nos modelos multivariados de volatilidade. Engle e Kroner (1995) propõem uma nova parametrização de H_t , face ao modelo proposto por Bollerslev *et al.* (1988), que facilmente impõe a sua positividade. O modelo BEKK-GARCH (q, p), na forma completa, é definido como:

$$H_t = CC' + \sum_{i=1}^q A_i(\varepsilon_{t-i}\varepsilon'_{t-i})A_i' + \sum_{j=1}^p B_j H_{t-j} B_j' \quad (10)$$

onde C é uma matriz triangular inferior de ordem ($N \times N$), sendo CC' definida positiva. De igual modo, com a estimação das matrizes A_i e B_j , de ordem ($N \times N$), é assegurado que a matriz H_t é definida positiva. Os parâmetros do modelo BEKK não representam diretamente o impacto dos diferentes termos desfasados nos elementos de H_t , como acontece no modelo de Bollerslev, *et al.* (1988). O número de parâmetros neste modelo, com $q = p = 1$, é $N(5N + 1)/2$. Num processo GARCH bivariado, com $q = p = 1$, a equação (10) teria 11 parâmetros. Para reduzir o número de parâmetros a estimar, reduzir a sua generalidade e facilitar o processo de estimação, é frequentemente utilizado um modelo BEKK diagonal, onde A_i e B_j são matrizes diagonais, ou um modelo BEKK – escalar, onde A_i e B_j são especificadas como o produto de um escalar por uma matriz de 1's. A característica importante da especificação na equação (10) é que a matriz H_t é desenvolvida

sob suficiente generalidade, permitindo que as variâncias e covariâncias condicionais das séries se influenciem mutuamente.

Porém, apesar da larga utilização do modelo completo BEKK–GARCH em aplicações empíricas, existem problemas teóricos que lhe estão associados. Este modelo demonstrou não ter condições de regularidade e, assim, não ter propriedades estatísticas estabelecidas que permitam realizar os procedimentos de inferência (McAleer *et al.*, 2008; Allen e McAleer, 2018).

Assim, os efeitos *spillovers* de volatilidade podem ser considerados no modelo – BEKK-Diagonal, onde as propriedades estatísticas dos estimadores dos parâmetros estão estabelecidas. Este modelo é derivado a partir de um processo vetorial autorregressivo de ordem 1, de coeficientes aleatórios, que é a extensão multivariada do processo utilizado no desenvolvimento do modelo GARCH univariado (McAleer *et al.*, 2008):

$$\varepsilon_t = \Phi_t \varepsilon_{t-1} + \eta_t \quad (11)$$

onde ε_t e η_t são vetores ($N \times 1$), Φ_t é uma matriz ($N \times N$) de coeficientes aleatórios, $\Phi_t \sim iid(0, A)$, sendo A uma matriz definida positiva, $\eta_t \sim iid(0, C)$ e C uma matriz ($N \times N$).

No caso em que A é uma matriz diagonal, com $a_{ii} > 0$, para todo $i = 1, 2, \dots, N$ e $|b_{jj}| < 1$, para todo $j = 1, 2, \dots, N$, tal que A tem dimensão ($N \times N$), McAleer *et al.*, (2008) mostraram que a extensão multivariada do modelo univariado GARCH(1,1), a partir da equação (6), é dada pelo modelo BEKK-diagonal:

$$H_t = CC' + A(\varepsilon_{t-1} \varepsilon_{t-1}')A' + B H_{t-1} B' \quad (12)$$

onde A e B são matrizes diagonais. A diagonalidade da matriz definida positiva A é essencial para a multiplicação da matriz dado que $\varepsilon_{t-1} \varepsilon_{t-1}'$ é uma matriz ($N \times N$); de outro modo, a equação (12) não poderia ser derivada do processo vetorial autorregressivo de coeficientes aleatórios na equação (11).

McAleer *et al.*, (2008) demonstraram que os estimadores de Quase - Máxima Verosimilhança (QMV) dos parâmetros do modelo BEKK-Diagonal são consistentes e assintoticamente normais, permitindo que as inferências estatísticas comuns nos testes de hipóteses sejam válidas.

Por outro lado, os autores notam que o modelo completo BEKK não é derivado de qualquer processo estocástico conhecido, o que significa não existirem condições de regularidade (exceto por suposição) para verificar a consistência interna do modelo e, conseqüentemente, não existirem propriedades assintóticas válidas dos estimadores de QMV dos parâmetros (exceto por suposição). Isto porque, à medida que o número de

variáveis no modelo aumenta, verifica-se um aumento significativo do número de parâmetros a estimar, levando a que a convergência do algoritmo de estimação dos parâmetros se torne problemática e as propriedades dos estimadores não sejam definidas. Mesmo com 3 variáveis/mercados no modelo, e apesar da convergência do algoritmo de estimação ser mais provável, a interpretação das estimativas do modelo ainda é problemática.

Assim, na análise empírica, a fim de examinar os efeitos *spillovers* ARCH (captados pelos coeficientes a_{ii}) e GARCH (captados pelos coeficientes b_{jj}), utilizamos o modelo BEKK-diagonal. Este modelo permite testar os efeitos *spillover* de co-volatilidade, que é o efeito de um choque no mercado j , no período $t - 1$, na co-volatilidade subsequente entre o mercado i e o mercado j , $i \neq j$, no período t . O efeito de *spillover* de co-volatilidade é definido como $\frac{\partial H_{ij,t}}{\partial \varepsilon_{j,t-1}} = a_{ii}a_{jj}\varepsilon_{i,t-1}$, $i \neq j$. Como $a_{ii} > 0$ para todo o i , um teste ao efeito *spillover* de co-volatilidade é um teste à hipótese nula: $H_0: a_{ii}a_{jj} = 0$, $i \neq j$, assumindo que $\varepsilon_{i,t-1} \neq 0$. Se H_0 é rejeitada contra a hipótese alternativa, $H_1: a_{ii}a_{jj} \neq 0$, existe um efeito *spillover* de um choque na rendibilidade no mercado j no período $t - 1$ na co-volatilidade entre os mercados i e j em t , que depende apenas do choque na rendibilidade do mercado i no período $t - 1$. De igual modo, o teste ao efeito de um choque na rendibilidade de um mercado no período $t - 1$, na sua própria volatilidade no período t , consiste no teste à hipótese nula $H_0: a_{ii} = 0$.

O modelo permite analisar também o efeito *spillover* da co-volatilidade entre os mercados i e j no período $t - 1$ na própria co-volatilidade entre os dois mercados no período t . O teste a este efeito é um teste à hipótese nula: $H_0: b_{ii}b_{jj} = 0$, $i \neq j$. Por sua vez, o teste ao efeito de um choque na volatilidade de um mercado no período $t - 1$, na sua própria volatilidade no período t , consiste no teste à hipótese nula $H_0: b_{ii} = 0$.

3.3.2. Modelo com Correlação Condicional Dinâmica - DCC- MGARCH

Nesta subsecção apresenta-se o modelo multivariado de heteroscedasticidade condicional autorregressiva generalizada, com correlação condicional dinâmica, DCC-MGARCH, que será utilizado para examinar os co-movimentos de variações de preços entre os mercados financeiros nacionais e os mercados do petróleo e do Ouro.

Este modelo pode ser visto como uma combinação não-linear de modelos GARCH univariados. Isto permite que o modelo possa ser especificado separadamente, por um lado,

com as variâncias condicionais individuais e, por outro, com a matriz de correlação condicional. Face ao modelo BEKK-GARCH, este modelo envolve a estimação de um menor número de parâmetros e, por isso, é mais facilmente estimado.

A matriz de variância condicional deste modelo é especificada de forma hierárquica. Primeiro, para cada variância condicional é escolhido um modelo tipo GARCH. Por exemplo, para um dado mercado a variância condicional pode seguir um modelo GARCH convencional enquanto para outros a variância condicional pode seguir um modelo EGARCH. Segundo, baseado nas variâncias condicionais, é especificada a matriz de correlação condicional (impondo que esta seja definida positiva para $\forall t$).

Engle (2002) propõe o modelo DCC-MGARCH, definido como:

$$H_t = D_t R_t D_t \quad (13)$$

onde:

$$D_t = \text{diag}(h_{11,t}^{\frac{1}{2}} \dots h_{NN,t}^{\frac{1}{2}}) \quad (14)$$

e onde $h_{ii,t}$ pode ser definido como qualquer modelo GARCH uni-variado, com

$$R_t = \text{diag}\left(q_{11,t}^{-\frac{1}{2}} \dots q_{NN,t}^{-\frac{1}{2}}\right) Q_t \text{diag}\left(q_{11,t}^{-\frac{1}{2}} \dots q_{NN,t}^{-\frac{1}{2}}\right) \quad (15)$$

onde a matriz $Q_t = (q_{ij,t})$, definida positiva e simétrica ($N \times N$), é dada por:

$$Q_t = \left(1 - \sum_{i=1}^q \alpha_i - \sum_{j=1}^p \beta_j\right) \bar{Q} + \sum_{i=1}^q \alpha_i (u_{t-i} u'_{t-i}) + \sum_{j=1}^p \beta_j Q_{t-j} \quad (16)$$

onde $\bar{Q} = (1/T) \sum_{t=1}^T (u_t u'_t)$ é a matriz de covariâncias não-condicionais dos resíduos normalizados, $u_t = \varepsilon_t \left[\text{diag}(h_{11,t}^{\frac{1}{2}} \dots h_{NN,t}^{\frac{1}{2}}) \right]^{-1}$, com $\alpha_i \geq 0$, $\beta_j \geq 0$, $\sum_{i=1}^q \alpha_i + \sum_{j=1}^p \beta_j < 1$. Se as variâncias condicionais forem estimadas usando um modelo GARCH(1,1) a matriz Q_t vem:

$$Q_t = (1 - \alpha - \beta) \bar{Q} + \alpha u_{t-1} u'_{t-1} + \beta Q_{t-1} \quad (17)$$

onde α e β são parâmetros escalares não-negativos, satisfazendo $\alpha + \beta < 1$. Num modelo bivariado, usando o modelo GARCH(1,1) na estimação das variâncias condicionais, a expressão do coeficiente de correlação vem:

$$\rho_{12,t} = \frac{(1-\alpha-\beta)\bar{q}_{12} + \alpha u_{1,t-1} u_{2,t-1} + \beta q_{12,t-1}}{\sqrt{((1-\alpha-\beta)\bar{q}_{11} + \alpha u_{1,t-1}^2 + \beta q_{11,t-1})((1-\alpha-\beta)\bar{q}_{22} + \alpha u_{2,t-1}^2 + \beta q_{22,t-1})}} \quad (18)$$

Como se observa nas equações (16) e (17), a matriz Q_t é formulada como uma equação GARCH, e depois transformada na matriz de correlações. Segundo Bauwens *et al.* (2006), uma desvantagem deste modelo na modelização dos co-movimentos das séries é que os α e β são escalares, levando a que todas as correlações condicionais obedeçam à mesma dinâmica.

4. Resultados e Discussão

4.1. Estatísticas Descritivas

As tabelas 2, 3 e 4 apresentam as estatísticas descritivas para o período da crise financeira global 2007-2009, crise da dívida soberana, e crise Covid-19 respectivamente. A crise Covid-19 apresenta retornos médios positivos em todas as séries dos retornos, sendo que o S&P500 apresenta o maior valor, 7,4%, e o FTSE100 o menor, 0,15%. A *commodity* com o valor médio mais alto é o WTI, com 3,99%.

Na crise da dívida soberana as séries dos retornos do CSI300 e do MIB apresentam retornos médios negativos com o CSI300 a apresentar o valor mais baixo, -2,9%, e as restantes séries valores positivos, com o S&P500 a apresentar o maior valor, 4,8%. Nas *commodities* a série do Brent é a que apresenta o maior valor, 3,4%.

Na crise financeira global todos os índices acionistas apresentam valores negativos, com o MIB a apresentar o valor mais baixo, -7,8%. Todas as *commodities* apresentam valores positivos; no entanto, as séries do petróleo apresentam valores muito próximos de zero, enquanto o Ouro apresenta o maior valor, com 7,9%, sendo este o maior valor registado nos três períodos de crise analisados.

Quanto à análise dos valores do desvio padrão, considerado como medida de risco não-condicional, para os índices financeiros no período da crise da dívida soberana e da Covid-19 os valores são relativamente idênticos, oscilando entre 1 e 1,9. É no período da crise financeira global 2007-2009 que os valores deste indicador são mais elevados, todos acima de 2%, indicando que foi neste período que os mercados financeiros apresentaram maior risco. O mercado do petróleo apresentou valores ainda maiores, com o WTI a registar o mais elevado do período, 3,37%. Foi também neste período que o Ouro apresentou o maior valor face aos outros períodos de crises, no entanto com um valor pouco expressivo, 1,56%.

Em relação ao mercado do petróleo, foi no período da Covid-19 que se verificaram os maiores níveis de risco, com o Brent e o WTI a apresentarem valores de 3,42% e 5,1%, respectivamente. Estes resultados indicam que, durante os três períodos de crises financeiras e no conjunto dos mercados financeiros e de *commodities* analisados, é o mercado de petróleo que evidencia maior nível de risco e que é o período de crise Covid-19 que exerce maior impacto no risco do preço do petróleo.

A assimetria mede o grau de desvio da distribuição da série dos retornos em relação à distribuição normal. Uma distribuição assimétrica positiva (negativa), face à normal,

evidência uma maior concentração de valores na cauda esquerda (direita) da distribuição e uma cauda direita (esquerda) com maior massa de probabilidade no domínio superior (inferior) da distribuição, observando-se a ocorrência de valores extremos superiores (inferiores) com maior frequência. Uma distribuição simétrica apresenta um coeficiente de assimetria nulo.

No período da crise financeira global 2007-2009 as séries do Brent, CSI300, FTSE100, NIKKEI, S&P500 e TSX apresentam assimetria negativa e as restantes assimetria positiva. No período da crise da dívida soberana verifica-se assimetria negativa em todas as séries, sugerindo a ocorrência de variações negativas extremas (*i.e.*, quedas abruptas dos mercados) com uma probabilidade superior à esperada sob condições normais. Por último, no período Covid-19, e à semelhança do verificado no período da crise de dívida soberana, todas as séries evidenciam assimetria negativa, com a exceção do NIKKEI, sugerindo igualmente que neste período todos os mercados evidenciaram um elevado risco de queda.

A curtose é uma medida de achatamento da função de distribuição de probabilidade, e que mede o volume de concentração ou de afastamento das observações em torno da média presentes na distribuição. No caso de o valor ser superior a 3, estamos perante uma função leptocúrtica, *i.e.*, uma função achatada onde a massa de probabilidade das observações concentradas em torno da média é superior ao esperado sob uma distribuição normal e onde a ocorrência de observações extremas, em ambas as caudas, também é superior.

Nos três períodos amostrais todas as séries apresentam valores superiores a 3, classificando-se como leptocúrticas. No período Covid-19 os valores de curtose do petróleo apresentam valores muito elevados face aos dois outros períodos, e o WTI apresenta o valor mais elevado de todos os períodos. Estes valores elevados indicam que as séries possuem um número elevado de observações extremas, o que seria de esperar devido aos efeitos que a crise Covid-19 provocou no mercado do petróleo.

A estatística Jarque-Bera testa a hipótese nula da série dos retornos seguir uma distribuição normal. Observando a significância associada à estatística Jarque-Bera é possível verificar que, em todos os períodos e para todas as séries, rejeitamos a hipótese nula, implicando que as séries dos retornos não seguem uma distribuição normal. Consultando as figuras 5, 6 e 7, presentes em apêndice, é possível constatar visualmente que as séries não seguem uma distribuição normal e que a distribuição *t-student* se apresenta como mais adequada. Por esta razão todos os modelos multivariados GARCH estimados neste trabalho assumem-se seguir a distribuição *t-student*.

Foram calculadas as estatísticas Ljung-Box para os *lags* 4 e 12, tanto para a série dos retornos como para a série dos quadrados dos retornos. No período da crise financeira

global 2007-2009 as séries demonstram estarem autocorrelacionadas, com exceção do CSI300 e do Ouro. No período da crise da dívida soberana apenas as séries do Brent, CSI300, Ouro e WTI não apresentam autocorrelação. No período da crise do Covid-19 as séries do Brent, CSI300, FTSE100 e do Ouro não apresentam autocorrelação. Na estimação dos modelos GARCH, a existência de autocorrelação nas séries dos retornos é problemática por implicar a existência de dependência linear, podendo os parâmetros nas equações das médias condicionais não serem devidamente captados. De forma a remover a autocorrelação e a dependência linear são utilizados os modelos VAR ou VECM para, de seguida, se poder aplicar os modelos GARCH às séries dos resíduos e, assim, modelar o comportamento da variância condicional da variável dependente. A adequação da aplicação dos modelos GARCH às séries dos resíduos é suportada pela significância das estatísticas Ljung-Box para os *lags* 4 e 12, aplicadas ao quadrado das séries dos retornos, que sugerem a presença de *clusters* de volatilidade diferenciados.

Tabela 2: Estatísticas descritivas do período da crise financeira global 2007-2009

	DLBrent	DLCAC40	DLCSI300	DLDAX	DLFTSE100	DLOuro	DLNIKKEI	DLMIB	DLSP500	DLTSX	DLWTI
Média	0.005658	-0.051137	-0.013281	-0.029812	-0.059761	0.079233	-0.042467	-0.077519	-0.044866	-0.025676	0.009004
Mediana	0.014557	0.000000	0.067867	0.000000	0.000000	0.079190	0.000000	0.000000	0.020214	0.164549	0.000000
Máximo	12.70660	24.29041	8.917670	23.31837	10.86103	8.624971	17.64611	23.18703	10.95720	10.56720	16.40973
Mínimo	-10.94552	-12.79473	-8.408229	-13.00048	-9.822646	-6.054372	-18.01241	-12.76043	-9.469514	-12.70360	-13.06537
Desvio Padrão	2.949808	2.698036	2.450785	2.648853	2.239577	1.563875	2.496191	2.692198	2.026995	2.536667	3.373193
Assimetria	-0.080547	0.944123	-0.216683	0.939381	-0.083554	0.224904	-0.383022	0.778060	-0.133252	-0.566666	0.168697
Curtose	5.103529	16.66598	4.163104	16.67014	7.185474	6.011686	14.49139	14.78459	8.082855	6.453252	6.198151
Jarque-Bera Probability	117.7604 0.000000	5035.665 0.000000	40.76217 0.000000	5037.731 0.000000	464.2411 0.000000	245.3370 0.000000	3509.405 0.000000	3738.511 0.000000	685.4412 0.000000	349.4985 0.000000	273.6322 0.000000
Ljung-Box-Q(4)	11.060 [0.026]	44.030 [0.00]	4.3112 [0.366]	28.729 [0.001]	18.012 [0.001]	4.7305 [0.316]	54.117 [0.00]	32.532 [0.00]	24.216 [0.00]	10.528 [0.032]	14.530 [0.006]
Ljung-Box-Q ² (12)	33.350 [0.001]	59.112 [0.00]	6.7205 [0.876]	40.671 [0.00]	32.407 [0.00]	27.533 [0.006]	77.338 [0.00]	50.654 [0.00]	31.902 [0.00]	29.499 [0.003]	24.266 [0.019]
Ljung-Box-Q ² (4)	95.569 [0.00]	58.148 [0.00]	19.319 [0.00]	50.178 [0.00]	115.94 [0.00]	39.228 [0.00]	157.89 [0.00]	61.048 [0.00]	142.61 [0.00]	142.61 [0.00]	104.39 [0.00]
Ljung-Box-Q ² (12)	400.16 [0.00]	110.84 [0.00]	47.766 [0.00]	107.56 [0.00]	462.72 [0.00]	88.086 [0.00]	231.66 [0.00]	103.87 [0.00]	576.72 [0.00]	576.72 [0.00]	340.06 [0.00]
Observations	635	635	635	635	635	635	635	635	635	635	635

Notas: Ljung-Box-Q(p) é a estatística do teste de Ljung-Box-Q que testa a hipótese nula de não existência de autocorrelação nas séries dos retornos até ao desfaseamento p. Ljung-Box-Q²(p) é a estatística do mesmo teste que testa a hipótese nula da série do quadrado dos retornos apresentar um comportamento de ruído branco, i.e., média ($\mu_t = 0$) e variância ($\sigma_t^2 = k$) constantes. A estatística de Jarque-Bera testa a hipótese nula da série dos retornos seguirem uma distribuição normal.

Tabela 3: Estatísticas descritivas do período da crise da dívida soberana

	DLBrent	DLCAC40	DLCSI300	DLDEX	DLFTSE100	DLOuro	DLMIB	DLNIKKEI	DLSP500	DLTSX	DLWTI
Média	0.033773	0.004863	-0.029485	0.041266	0.023012	0.008866	-0.023571	0.029192	0.048499	0.013101	0.020657
Mediana	0.064485	0.027545	0.000000	0.048435	0.009551	0.032117	0.000000	0.000000	0.045010	0.012917	0.010640
máximo	6.811683	9.402116	9.089160	5.815059	5.564348	4.617584	10.86530	6.460464	4.631738	4.200399	8.945401
Mínimo	-8.963279	-7.532095	-10.71653	-7.125757	-6.225739	-9.820577	-9.047934	-11.81069	-6.895833	-4.875877	-9.037911
Desvio Padrão	1.525756	1.623238	1.423761	1.509993	1.206019	1.190682	1.884683	1.346709	1.052207	1.086170	1.691064
Assimetria	-0.305669	-0.178318	-0.317069	-0.324642	-0.203897	-1.159162	-0.242150	-1.111960	-0.473702	-0.346992	-0.126149
Curtose	5.304925	5.733942	8.857424	5.030055	5.051416	10.09405	5.354559	11.22177	7.593007	5.533443	5.687123
Jarque-Bera	246.8852	330.0373	1507.060	197.2285	189.9308	2418.316	250.8831	3149.586	954.8752	299.5726	316.2594
Probability	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
Ljung-Box-Q(4)	2.5905 [0.629]	31.021 [0.00]	4.5976 [0.331]	48.776 [0.00]	13.546 [0.009]	1.9708 [0.741]	26.598 [0.00]	26.427 [0.00]	26.236 [0.00]	34.213 [0.00]	0.9340 [0.920]
Ljung-Box-Q(12)	7.4886 [0.824]	38.586 [0.00]	23.706 [0.022]	59.328 [0.00]	20.999 [0.050]	9.1649 [0.689]	32.388 [0.00]	39.911 [0.00]	41.219 [0.00]	48.979 [0.00]	3.1153 [0.995]
Ljung-Box-Q ² (4)	76.366 [0.00]	98.878 [0.00]	70.240 [0.00]	148.89 [0.00]	64.031 [0.00]	19.554 [0.00]	99.751 [0.00]	73.076 [0.00]	323.51 [0.00]	323.51 [0.00]	52.778 [0.00]
Ljung-Box-Q ² (12)	84.991 [0.00]	208.49 [0.00]	73.208 [0.00]	407.71 [0.00]	177.85 [0.00]	34.527 [0.00]	186.32 [0.00]	86.907 [0.00]	548.62 [0.00]	548.62 [0.00]	67.057 [0.00]
Observations	1042	1042	1042	1042	1042	1042	1042	1042	1042	1042	1042

Notas: Ljung-Box-Q(p) é a estatística do teste de Ljung-Box-Q que testa a hipótese nula de não existência de autocorrelação nas séries dos retornos até ao desfasamento p. Ljung-Box-Q²(p) é a estatística do mesmo teste que testa a hipótese nula da série do quadrado dos retornos apresentar um comportamento de ruído branco, i.e., média ($\mu_t = 0$) e variância ($\sigma_t^2 = k$) constantes. A estatística de Jarque-Bera testa a hipótese nula da série dos retornos seguirem uma distribuição normal.

Tabela 4: Estatísticas descritivas do período da crise Covid-19

	DLBrent	DLCAC40	DLCSI300	DLDAX	DLFTSE100	DLOuro	DLMIB	DLNIKKEI	DLSP500	DLTSX	DLWTI
Média	0.031401	0.036393	0.053389	0.037710	0.001492	0.034953	0.031956	0.028151	0.074344	0.046395	0.039852
Mediana	0.277907	0.106511	0.019527	0.063956	0.013496	0.052835	0.075521	0.000000	0.140092	0.133081	0.194269
máximo	19.07740	8.710539	5.514330	11.06875	8.430013	5.775363	9.204991	7.467342	8.968316	11.17351	31.96337
Mínimo	-27.97615	-13.58546	-8.642180	-13.54197	-12.22380	-5.113959	-19.03322	-6.330940	-12.76521	-13.47580	-60.16758
Desvio Padrão	3.427584	1.591150	1.313828	1.617826	1.477095	1.145367	1.731451	1.355871	1.622722	1.598033	5.101031
Assimetria	-1.743556	-1.213885	-0.749117	-0.851064	-1.049194	-0.351374	-2.807480	0.082778	-1.062553	-2.145020	-3.042200
Curtose	22.54871	17.62248	7.738828	17.89376	15.31710	7.846522	34.75481	7.473237	18.38240	29.15108	49.21194
Jarque-Bera Probability	8592.720 0.000000	4787.867 0.000000	538.2802 0.000000	4897.054 0.000000	3401.986 0.000000	522.6215 0.000000	22661.06 0.000000	436.6453 0.000000	5254.716 0.000000	15303.93 0.000000	47343.77 0.000000
Ljung-Box-Q(4)	7.5310 [0.110]	17.190 [0.00]	1.8245 [0.768]	13.093 [0.00]	6.6991 [0.153]	6.5286 [0.163]	26.933 [0.00]	14.039 [0.00]	88.029 [0.00]	20.710 [0.00]	23.616 [0.00]
Ljung-Box-Q(12)	16.237 [0.181]	49.403 [0.00]	5.4271 [0.942]	47.544 [0.00]	29.996 [0.00]	23.484 [0.024]	54.776 [0.00]	31.862 [0.00]	247.48 [0.00]	101.39 [0.00]	36.046 [0.00]
Ljung-Box-Q ² (4)	29.467 [0.00]	101.83 [0.00]	3.8233 [0.430]	64.935 [0.00]	82.563 [0.00]	35.008 [0.00]	48.821 [0.00]	214.66 [0.00]	422.11 [0.00]	315.30 [0.00]	66.838 [0.00]
Ljung-Box-Q ² (12)	88.644 [0.00]	187.88 [0.00]	16.214 [0.182]	165.04 [0.00]	210.43 [0.00]	87.978 [0.00]	74.505 [0.00]	458.49 [0.00]	750.21 [0.00]	518.32 [0.00]	98.623 [0.00]
Observations	523	523	523	523	523	523	523	523	523	523	523

Notas: Ljung-Box-Q(p) é a estatística do teste de Ljung-Box-Q que testa a hipótese nula de não existência de autocorrelação nas séries dos retornos até ao desfaseamento p. Ljung-Box-Q²(p) é a estatística do mesmo teste que testa a hipótese nula da série do quadrado dos retornos apresentar um comportamento de ruído branco, i.e., média ($\mu_t = 0$) e variância ($\sigma_t^2 = k$) constantes. A estatística de Jarque-Bera testa a hipótese nula da série dos retornos seguirem uma distribuição normal.

4.2. Testes de raízes unitárias e de cointegração

De forma a proceder à avaliação da estacionariedade das séries foram utilizados os testes ADF e PP, amplamente utilizados na literatura, e que têm como hipótese nula a presença de uma raiz unitária contra a hipótese alternativa de estacionariedade. Na tabela 5 são apresentadas as estatísticas e respectivas significâncias dos testes realizados sobre o logaritmo das variáveis para cada período temporal. Os resultados dos testes indicam que nenhuma variável é estacionária em nível. Após proceder à transformação das séries, utilizando as primeiras diferenças dos logaritmos, todas as séries se revelam estacionárias ao nível de significância de 1%. Assim, na estimação dos modelos multivariados GARCH, os valores das séries são as primeiras diferenças do logaritmo do nível do índice.

Tabela 5: Resultados dos testes de estacionariedade ADF e PP

Crise financeira global 2007-2009				
Variáveis	Teste ADF		Teste PP	
	Nível	1ª diferença	Nível	1ª diferença
lBrent	0.0776	-4.6450***	-0.0371	-27.4241***
lcac40	-0.6215	-12.3038***	-0.6557	-31.1338***
lcsi300	-0.1902	-24.7843***	-0.1900	-24.7820***
ldax	-0.3501	-12.1635***	-0.3474	-29.8477***
lftse100	-0.8389	-11.9802***	-0.8282	-26.5192***
lOuro	1.3867	-10.5802***	1.1990	-23.4766***
lmib	-0.8716	-11.1919***	-0.8788	-29.1927***
lnikkei	-0.5674	-13.5359***	-0.6009	-32.0449***
lsp500	-0.7482	-21.5122***	-0.7332	-29.5560***
ltsx	-0.2868	-10.9702***	-0.3061	-26.4318***
lwti	-0.0479	-11.4451***	-0.0150	-26.4179***

Crise da Dívida Soberana				
Variáveis	Teste ADF		Teste PP	
	Nível	1ª diferença	Nível	1ª diferença
lBrent	0.6468	-32.4401***	0.6583	-32.4402***
lcac40	0.0308	-17.9218***	0.0721	-28.2217***
lcsi300	-0.6241	-9.1615***	-0.7368	-33.7307***
ldax	0.8870	-12.1547***	0.8595	-26.6094***
lftse100	0.6323	-12.4337***	0.6476	-30.3060***
lOuro	0.2061	-33.3177***	0.2226	-33.3784***
lmib	-0.4875	-17.4772***	-0.4388	-28.1959***
lnikkei	0.8770	-37.4176***	0.8831	-38.1214***
lsp500	1.6573	-15.9062***	1.7382	-34.8688***
ltsx	0.2980	-14.7982***	0.3864	-26.8286***
lwti	0.3311	-32.3244***	0.3364	-32.3276***

Crise Covid-19				
Variáveis	Teste ADF		Teste PP	
	Nível	1ª diferença	Nível	1ª diferença
lBrent	0.0883	-20.4608***	0.0839	-20.5557***
lcac40	0.4445	-8.3699***	0.4356	-22.7764***
lcsi300	0.8999	-21.6379***	0.8763	-21.6379***
ldax	0.4300	-5.4977***	0.4536	-23.0767***
lftse100	-0.0222	-5.4662***	-0.0023	-21.7087***
lOuro	0.7883	-11.6217***	0.8132	-22.7952***
lmib	0.2837	-6.3691***	0.3446	-24.6649***
lnikkei	0.3581	-5.1130***	0.4128	-23.5218***
lsp500	0.9111	-4.8207***	1.2509	-30.5715***
ltsx	0.4400	-6.6483***	0.5503	-25.0061***
lwti	0.0958	-5.4100***	0.0629	-25.0038***

Para testar a cointegração entre os conjuntos das variáveis foi utilizado o teste de Johansen. Para as análises com o modelo BEKK-diagonal as variáveis foram agrupadas em grupos de três, onde cada grupo consiste no índice financeiro de cada país e no conjunto das duas *commodities*, Ouro e Petróleo. Há também um grupo que consiste apenas nas três *commodities*. No caso das análises com o modelo DCC-MGARCH, as variáveis foram agrupadas por continentes. O grupo dos países americanos consiste no S&P500, TSX, WTI e Ouro; o grupo dos países asiáticos consiste no CSI300, NIKKEI, Brent e Ouro; por último, o grupo dos países europeus consiste no CAC40, DAX, FTSE100, MIB, Brent e Ouro.

Nas tabelas 6 e 7 estão apresentados, para cada período, os resultados dos testes de cointegração e o respectivo modelo escolhido para as estimações do modelo BEKK-diagonal e DCC-MGARCH. De notar que, de forma a facilitar a leitura e a não tornar o trabalho demasiado “pesado” em termos de quantidade de dados estatísticos, nas tabelas aparece apenas indicado se existe ou não cointegração, tendo sido omitidos de entre outros, a tendência determinística, a quantidade de vetores de cointegração, o teste de traço e o teste de máximo autovalor. O teste de cointegração indica qual o modelo a utilizar: no caso de cointegração utiliza-se o modelo VECM e o modelo VAR no caso de não-cointegração. A utilização destes modelos vai permitir remover a autocorrelação e, conseqüentemente, remover a dependência linear, permitindo aplicar os modelos GARCH multivariados para modelar o comportamento da variância condicional.

Tabela 6: Teste de cointegração Johansen e seleção de modelos para as equações da média condicional na estimação do modelo BEKK-diagonal

Crise Financeira Global		
Variáveis	Cointegração	Modelo
lcac40/lBrent/lOuro	Sim	VECM
lcsi300/lBrent/lOuro	Sim	VECM
ldax/lBrent/lOuro	Não	VAR
lftse100/lBrent/lOuro	Sim	VECM
lmib/lBrent/lOuro	Não	VAR
lnikkei/lBrent/lOuro	Sim	VECM
lsp500/lwti/lOuro	Não	VAR
ltsx/lwti/lOuro	Não	VAR
lOuro/lwti/lBrent	Sim	VECM
Divida Soberana		
Variáveis	Cointegração	Modelo
lcac40/lBrent/lOuro	Sim	VECM
lcsi300/lBrent/lOuro	Não	VAR
ldax/lBrent/lOuro	Não	VAR
lftse100/lBrent/lOuro	Não	VAR
lmib/lBrent/lOuro	Não	VAR
lnikkei/lBrent/lOuro	Não	VAR
lsp500/lwti/lOuro	Não	VAR
ltsx/lwti/lOuro	Não	VAR
lOuro/lwti/lBrent	Não	VAR
Covid-19		
Variáveis	Cointegração	Modelo
lcac40/lBrent/lOuro	Não	VAR
lcsi300/lBrent/lOuro	Não	VAR
ldax/lBrent/lOuro	Sim	VECM
lftse100/lBrent/lOuro	Não	VAR
lmib/lBrent/lOuro	Não	VAR
lnikkei/lBrent/lOuro	Não	VAR
lsp500/lwti/lOuro	Não	VAR
ltsx/lwti/lOuro	Não	VAR
lOuro/lwti/lBrent	Sim	VECM

Tabela 7: Teste de cointegração Johansen e seleção de modelos para as equações da média condicional na estimação do modelo DCC-MGARCH

Crise Financeira Global		
Variáveis	Cointegração	Modelo
lcac40/ldax/lftse100/lmib/lBrent/IOuro	Não	VAR
lcsi300/lnikkei/lBrent/IOuro	Não	VAR
lsp500/ltsx/lwti/IOuro	Sim	VECM
Divida Soberana		
Variáveis	Cointegração	Modelo
lcac40/ldax/lftse100/lmib/lBrent/IOuro	Não	VAR
lcsi300/lnikkei/lBrent/IOuro	Não	VAR
lsp500/ltsx/lwti/IOuro	Sim	VAR
Covid-19		
Variáveis	Cointegração	Modelo
lcac40/ldax/lftse100/lmib/lBrent/IOuro	Sim	VECM
lcsi300/lnikkei/lBrent/IOuro	Sim	VECM
lsp500/ltsx/lwti/IOuro	Não	VAR

4.3. Modelo BEKK-Diagonal

É possível verificar diretamente os efeitos de transmissão dos choques dos retornos não-esperados na co-volatilidade (covariância) entre os diferentes mercados através do teste à significância das estimativas dos coeficientes da matriz A no modelo BEKK-diagonal. Se a hipótese nula é rejeitada, haverá efeitos de transmissão dos choques do retorno não-esperado do mercado i em $t-1$ na co-volatilidade entre os mercados i e j , que depende apenas do choque do retorno não-esperado no mercado i em $t-1$.

As tabelas apresentadas em apêndice, nos apêndices B, C e D, contém as estimativas dos coeficientes para os três períodos de crise em estudo, considerando individualmente o mercado financeiro de cada país com os mercados do Ouro e do petróleo. O mercado do WTI é considerado para o S&P500 e TSX e o mercado do Brent para os restantes mercados. O modelo foi ainda estimado considerando apenas os mercados de *commodities*, analisando em conjunto apenas o Ouro com o Brent e o WTI.

A partir das estimativas da matriz A do modelo BEKK - diagonal, apresentadas nas tabelas 12 a 38, presentes nos apêndices B, C e D, em apêndice, constata-se que os coeficientes associados a cada conjunto dos três mercados, bem como do mercado do Ouro e mercado do petróleo são estatisticamente significativos ao nível de 1%. Estes resultados evidenciam a existência de efeitos de transmissão significativos nas co-volatilidades subsequentes entre os três mercados, condicional ao pressuposto de que o choque no retorno observado no correspondente mercado no período anterior não é nulo, $\varepsilon_{i,t-1} \neq 0$. Estes resultados mostram que, em todos os mercados, e em todos os períodos de crise analisados, os choques

dos retornos não-esperados no período $t - 1$ tendem a exercer efeitos positivos e significativos na co-volatilidade subsequente entre os respectivos mercados. Ou seja, os choques nos retornos não-esperados, positivos ou negativos, tendem a aumentar o grau do co-movimento (correlação) entre os dois mercados.

Por sua vez, a partir das estimativas da matriz B do modelo BEKK - diagonal, apresentadas nas tabelas 12 a 38, presentes nos apêndices B, C e D, em apêndice, os coeficientes associados aos três mercados, em todos os períodos de crise, são estatisticamente significativos ao nível de 1%, evidenciando a existência de efeitos de persistência significativos na co-volatilidade entre os mercados. Ou seja, a co-volatilidade entre os vários mercados tende a evidenciar um processo autorregressivo significativo ao longo do tempo dado que o produto dos coeficientes das co-volatilidades nos períodos anteriores são próximos ou superiores a 0,9 com exceção do mercado NIKKEI. Durante o período Covid-19 este mercado apresenta um valor de 0.463 que, embora significativo a 1%, é muito inferior a todos os outros mercados.

De forma a realizar uma análise comparativa que nos permita perceber em que períodos de crise as transmissões foram mais intensas é necessário analisar o produto dos coeficientes associados aos termos dos choques dos retornos não-esperados que correspondem ao $A_i(\varepsilon_{t-i}\varepsilon'_{t-i})$ na equação (10). Por sua vez, de forma a analisar a persistência da co-volatilidade devemos analisar o produto dos coeficientes correspondentes à segunda parte da equação (10), que corresponde a B_jH_{t-j} . Com vista a facilitar a análise comparativa foram agregados na tabela 8 os produtos de ambos os coeficientes.

Tabela 8: Estimativas dos coeficientes dos efeitos de transmissão dos choques dos retornos não-esperados e das co-volatilidades anteriores nas co-volatilidades subsequentes no modelo BEKK (1,1) - diagonal.

		Crise Financeira global		Divida Soberana		Covid-19	
Mercados		$A_i(\varepsilon_{t-i}\varepsilon'_{t-i})$	(B_jH_{t-j})	$A_i(\varepsilon_{t-i}\varepsilon'_{t-i})$	(B_jH_{t-j})	$A_i(\varepsilon_{t-i}\varepsilon'_{t-i})$	(B_jH_{t-j})
CAC40	Brent	0.0678	0.9128	0.0708	0.8784	0.0759	0.8878
	Ouro	0.0563	0.9203	0.0377	0.9379	0.0339	0.9245
CSI300	Brent	0.0619	0.8970	0.0432	0.8547	0.0740	0.8160
	Ouro	0.0557	0.8979	0.0209	0.9027	0.0361	0.8540
DAX	Brent	0.0609	0.9273	0.0729	0.8774	0.0626	0.8979
	Ouro	0.0533	0.9321	0.0397	0.9379	0.0335	0.9301
FTSE100	Brent	0.0636	0.9098	0.1054	0.7816	0.0551	0.9014
	Ouro	0.0563	0.9135	0.0743	0.8920	0.0272	0.9329
MIB	Brent	0.0672	0.9156	0.0672	0.8956	0.0467	0.9094
	Ouro	0.0558	0.9213	0.0374	0.9399	0.0231	0.9408
NIKKEI	Brent	0.0518	0.9145	0.0489	0.9072	0.1933	0.4273
	Ouro	0.0458	0.9163	0.0276	0.9288	0.0925	0.4454
S&P500	WTI	0.0539	0.9380	0.1444	0.7459	0.1488	0.8181
	Ouro	0.0408	0.9477	0.0992	0.8648	0.0549	0.8830
TSX	WTI	0.0594	0.9235	0.0541	0.9158	0.1208	0.8400
	Ouro	0.0463	0.9334	0.0345	0.9428	0.0432	0.9017
Ouro	WTI	0.0437	0.93394	0.1216	0.7550	0.0532	0.8430
	Brent	0.0440	0.9379	0.1200	0.7662	0.0515	0.8585

Nota: todos os coeficientes são estatisticamente significativos a 1%

No período da crise financeira, o maior efeito de transmissão do retorno não-esperado na co-volatilidade condicional entre os mercados financeiros e o mercado do petróleo, verificou-se no CAC40 com 0.0678. O efeito de menor transmissão verificou-se no NIKKEI com 0.0518. Os países europeus e a China apresentam maiores intensidades de transmissão relativamente aos 2 países norte-americanos. Analisando as transmissões entre os mercados financeiros e o mercado do Ouro é possível verificar que os maiores valores são os correspondentes ao CAC40 e ao FTSE100 ambos com 0.0563, e o menor valor corresponde ao S&P500 com 0.0463.

No período da crise da dívida soberana a maior transmissão entre os mercados financeiros e o mercado do petróleo verificou-se no S&P500, com 0.1444, e a de menor transmissão verificou-se no CSI300, com 0.0432. Os países europeus e norte-americanos apresentam maiores intensidades de transmissão relativamente aos países asiáticos. Analisando as transmissões entre os mercados financeiros e o mercado do Ouro é possível verificar que o maior valor corresponde ao S&P500, com 0.0992, e o menor valor corresponde ao CSI300,

com 0.0209. Os países asiáticos são os que apresentam as intensidades de transmissão mais baixas.

No período da crise da Covid-19 a maior transmissão entre os mercados financeiros e o mercado do petróleo verificou-se no NIKKEI com 0.1933, e a menor transmissão verificou-se no MIB com 0.0467. Os países asiáticos e norte-americanos apresentam maiores intensidades de transmissão relativamente aos países europeus. Analisando as transmissões entre os mercados financeiros e o mercado do Ouro é possível verificar que o maior valor corresponde ao NIKKEI, com 0.0925. O de menor valor corresponde ao MIB, com 0.0231.

Fazendo uma análise comparativa entre os mercados, nos três períodos de crise, é possível observar que as maiores intensidades de transmissão de informação entre os mercados financeiros e o mercado do Ouro foram verificadas durante a crise financeira global 2007-2009, com exceção do FTSE100 e do S&P500, em que a intensidade foi superior durante a crise da dívida soberana. Por sua vez o NIKKEI registou a maior intensidade na crise da covid-19. Quanto às transmissões de informação entre os mercados financeiros e os mercados do petróleo, foi no período da Covid-19 que a maior parte dos mercados verificaram as maiores intensidades de transmissão, com a exceção do DAX-30 e FTSE100 que registaram as maiores intensidades no período da dívida soberana. O MIB apresentou valores superiores, mas idênticos nas crises financeira global 2007-2009 e na crise da dívida soberana. Também é possível observar que os valores são superiores na crise da dívida soberana em comparação com a crise financeira global 2007-2009, com exceção do CSI300 e NIKKEI que apresentaram valores inferiores.

Os resultados indicam que as transmissões do Ouro são inferiores às transmissões do petróleo para todos os mercados, em todos os períodos. Nos efeitos de transmissão entre os mercados de *commodities*, os registados entre o mercado do Ouro e o mercado do petróleo foram mais pronunciados durante o período da crise da dívida soberana, mas apresentaram valores mais baixos mas próximos durante o período da crise financeira e da Covid-19. Os resultados não tendem a evidenciar diferenças significativas quando se analisam separadamente as transmissões do Ouro com o Brent e o WTI porque os dois índices de preços do petróleo apresentam um comportamento idêntico face ao Ouro, com valores quase idênticos.

Comparando os efeitos de persistência na co-volatilidade entre os mercados financeiros e o mercado do petróleo, ou seja, o efeito da co-volatilidade do período anterior na co-volatilidade do período seguinte, verifica-se que é no período da crise financeira global 2007-2009 que se regista a maior persistência na co-volatilidade em todos os mercados. Os

efeitos de persistência também se revelam superiores durante o período da crise financeira global 2007-2009 quando analisamos apenas as interações entre as *commodities*. Entre os mercados financeiros e o mercado do Ouro, a maior persistência na co-volatilidade é verificada no período da dívida soberana, com exceção do FTSE100 e do MIB, que apresentam valores superiores no período da crise da covid-19.

4.4. Modelo DCC-MGARCH

Neste estudo o modelo DCC-MGARCH (1,1) é adotado para examinar as flutuações e dinâmicas das correlações condicionais entre os vários mercados. Os índices acionistas foram agrupados com as *commodities* por continente da seguinte forma. Para a análise no contexto europeu foram incluídos os índices CAC40, DAX, FTSE100, MIB, Brent e Ouro; para a análise no contexto asiático foram agrupados o CSI300, NIKKEI, Brent e Ouro; para a análise no contexto americano foram agrupados o S&P500, TSX, WTI e Ouro. As tabelas 9, 10, 11, presentes no corpo do texto, e as tabelas 39 a 44, presentes nos apêndices E, F e G, apresentam os resultados de estimação do modelo DCC-MGARCH (1,1) para os continentes europeu, asiático e americano durante os três períodos em análise.

Neste modelo os elementos na diagonal principal da matriz de variâncias-covariâncias condicionais das variáveis dependentes, H_t , são modeladas como modelos GARCH univariados, enquanto os elementos fora da diagonal. *i.e.*, as covariâncias condicionais, $h_{ij,t}$, são modeladas como funções não-lineares dos termos na diagonal da matriz H_t : $h_{ij,t} = \rho_{ij,t} \sqrt{h_{ii,t} h_{jj,t}}$. O termo $\rho_{ij,t}$, *i.e.*, a correlação condicional, segue o processo dinâmico especificado na equação (16), apresentada na seção de metodologia.

Os resultados nas tabelas 9, 10 e 11 mostram que para os mercados do continente americano as somas de α_1 e β_1 são superiores a 0.88, mas inferiores a 1, indicando uma persistência elevada nas variâncias condicionais das variáveis dependentes. Ou seja, os choques na variância condicional tendem a exercer um efeito algo prolongado para, de seguida, os respetivos valores esperados reverterem para os seus valores médios de longo prazo. Os valores médios dos coeficientes de correlação condicionais, $\overline{\rho_{ij,t}}$, especificados na equação (18), e que refletem a correlação não-condicional são significativos. As correlações entre o S&P500 e o TSX são muito idênticas em todos os períodos, sendo os valores muito próximos de 0.7. Relativamente aos mercados de *commodities*, é possível observar que as maiores correlações entre o WTI e os índices ocorreram durante o período da crise da dívida soberana com S&P500 e TSX a apresentarem valores de $\overline{\rho_{ij,t}} = 0.49$ e $\overline{\rho_{ij,t}} = 0.47$

respetivamente. A menor correlação observou-se no período da crise financeira global 2007-2009 no S&P500 ($\overline{\rho_{i,j,t}} = 0.22$). Entre o mercado do Ouro e os índices acionistas, o S&P500 apresenta valores de correlação inferiores ao TSX em todos os períodos, com o menor valor a verificar-se no período da crise financeira global 2007-2009 ($\overline{\rho_{i,j,t}} = 0.015$). O maior valor verificou-se durante o período da crise financeira global 2007-2009 no TSX ($\overline{\rho_{i,j,t}} = 0.47$). Entre o WTI e o Ouro o maior valor foi também verificado durante o período da crise financeira global 2007-2009 com $\overline{\rho_{i,j,t}} = 0.41$.

No que concerne os parâmetros de ajustamento, α e β , que governam de forma comum a evolução da correlação condicional entre os mercados incluídos no modelo, estes mostraram-se significativos ao nível de 1% com exceção do parâmetro α no período Covid-19 que não é significativo. Estes resultados oferecem evidência contra a hipótese de as correlações condicionais entre os mercados serem constantes, suportando a hipótese das correlações condicionais evidenciarem um comportamento dinâmico ao longo do tempo. Todavia, a soma dos coeficientes de ajustamento é, em todos os períodos, superior a 0.85, indicando que o processo descrito pelo modelo para as correlações condicionais evidência uma reversão para a média. A implicação subjacente a esta característica é que, em geral, para os mercados considerados no modelo, após a ocorrência de um choque, as correlações condicionais nos períodos seguintes tendem para os seus valores médios não-condicionais de longo prazo.

Tabela 9: Estimação do Modelo VAR(1) – DCC-MGARCH(1,1) para os mercados acionistas americanos e o mercado de *commodities* (S&P500, TSX, WTI, Ouro) no período Covid-19

	S&P500	TSX	WTI	Ouro
Painel A – Equações da média condicional				
Const.	0.09	0.04	0.05	0.04
S&P500	-0.27***	0.03	0.08	-0.04
TSX	-0.08	-0.14*	-0.34	0.007
WTI	0.006	0.01	0.06	-0.002
Ouro	0.15**	0.17***	0.04	0.02
Painel B – Equações da variância condicional				
$h_{ii,t} = \omega_0 + \alpha_1 \varepsilon_{i,t-1}^2 + \beta_1 h_{ii,t-1}$				
ω_0	0.0927***	0.1041**	0.2448	0.1459**
α_1	0.3031***	0.4132*	0.1699***	0.1221**
β_1	0.6696***	0.5664***	0.8290***	0.7663***
Painel C – Correlações médias condicionais ($\overline{\rho_{i,j,t}}$)				
S&P500		0.6967***	0.3955***	0.0743***
TSX			0.4303***	0.1724***
WTI				0.0649***
Coeficientes de ajustamento do processo de correlação condicional				
$\alpha = 0.0391$ (lambda 1)				
$\beta = 0.8147$ *** (lambda 2)				

Tabela 10: Estimação do Modelo VAR(1) – DCC-MGARCH(1,1) para os mercados acionistas americanos e o mercado de *commodities* (S&P500, TSX, WTI, Ouro) no período da dívida soberana.

	S&P500	TSX	WTI	Ouro
Painel A - Equações da média condicional				
Const.	0.05*	-0.003	0.02	0.01
S&P500(-1)	-0.15***	0.28***	-0.03	-0.05
TSX(-1)	0.08*	-0.08*	0.17**	0.11**
WTI(-1)	0.04*	0.05**	-0.03	0.01
Ouro(-1)	-0.03	0.06**	-0.06	-0.06*
Painel B - Equações da variância condicional				
$h_{ii,t} = \omega_0 + \alpha_1 \varepsilon_{i,t-1}^2 + \beta_1 h_{ii,t-1}$				
ω_0	0.0303***	0.0164**	0.0329	0.0560
α_1	0.1122***	0.0866***	0.0479*	0.0812
β_1	0.8582***	0.8980***	0.9412***	0.8826***
Painel C - Correlações médias condicionais ($\overline{\rho_{ij,t}}$)				
S&P500		0.6962***	0.4858***	0.1562***
TSX			0.4720***	0.3496***
WTI				0.3289
Coeficientes de ajustamento do processo de correlação condicional				
$\alpha = 0.0276***$ (lambda 1)				
$\beta = 0.9386***$ (lambda 2)				

Tabela 11: Estimação do Modelo VECM(1) – DCC-MGARCH(1,1) para os mercados acionistas americanos e o mercado de *commodities* (S&P500, TSX, WTI, Ouro) no período da crise financeira global 2007-2009.

	S&P500	TSX	WTI	Ouro
Painel A - Equações da média condicional				
Coint. Eq.	-0.02	0.02	-0.11***	-0.03**
S&P500(-1)	0.04	0.38***	0.29***	-0.01
TSX(-1)	-0.19***	-0.30***	-0.06	0.06
WTI(-1)	-0.03	0.02	-0.09*	-0.02
Ouro(-1)	0.05	0.09	0.02	0.05
Painel B - Equações da variância condicional				
$h_{ii,t} = \omega_0 + \alpha_1 \varepsilon_{i,t-1}^2 + \beta_1 h_{ii,t-1}$				
ω_0	0.0000	0.0000	0.0000	0.0000
α_1	0.0809***	0.1086***	0.0936***	0.0477***
β_1	0.9109***	0.8792***	0.8969***	0.9406***
Painel C - Correlações médias condicionais ($\overline{\rho_{ij,t}}$)				
S&P500		0.7041***	0.2182***	0.0145***
TSX			0.4663***	0.4663***
WTI				0.4103***
Coeficientes de ajustamento do processo de correlação condicional				
$\alpha = 0.0179***$ (lambda 1)				
$\beta = 0.9682***$ (lambda 2)				

Os resultados nas tabelas 39, 41 e 43, presentes em apêndice, mostram que para os mercados do continente europeu as somas de α_1 e β_1 são superiores a 0.9, mas inferiores a 1, indicando uma persistência elevada nas variâncias condicionais das variáveis

dependentes. Os seja, os choques na variância condicional tendem a exercer um efeito algo prolongado para, de seguida, os respetivos valores esperados reverterem para os seus valores médios de longo prazo. Os valores médios dos coeficientes de correlação condicionais, $\overline{\rho_{ij,t}}$, especificados na equação (18), e que refletem a correlação não-condicional, são significativos e evidenciam uma magnitude elevada entre os mercados acionistas, com o valor mais elevado nos três períodos a registar-se entre o CAC40 e DAX ($\overline{\rho_{ij,t}} = 0.96$, $\overline{\rho_{ij,t}} = 0.95$, $\overline{\rho_{ij,t}} = 0.91$) correspondendo, respetivamente, à crise financeira global 2007-2009, crise da dívida soberana e crise da Covid-19. Estes valores são consistentes com o maior grau de integração financeira observado entre estes dois mercados. Os restantes valores médios de correlação entre os vários mercados, com valores inferiores, refletem a sua menor integração financeira. As correlações com o mercado britânico (FTSE100) registam os menores valores, evidenciando assim a sua menor integração com os mercados da Europa continental. O menor valor de correlação entre mercados, em todos os períodos, corresponde aos co-movimentos entre o FTSE100 e MIB ($\overline{\rho_{ij,t}} = 0.82$, $\overline{\rho_{ij,t}} = 0.75$, $\overline{\rho_{ij,t}} = 0.79$) correspondendo, respetivamente, à crise financeira global 2007-2009, crise da dívida soberana e crise da Covid-19, demonstrando assim que os mercados britânico e italiano possuem a menor integração no quadro dos mercados europeus analisados.

Analisando as correlações dos mercados de commodities com os índices financeiros e as correlações entre os próprios mercados de *commodities* é possível observar que as maiores correlações foram observadas durante o período da crise financeira global 2007-2009. No mercado do Brent a maior correlação foi observada com o mercado britânico ($\overline{\rho_{ij,t}} = 0.44$), no mercado do Ouro o maior valor registou-se no DAX ($\overline{\rho_{ij,t}} = 0.24$), e a correlação entre o Brent e o Ouro foi de $\overline{\rho_{ij,t}} = 0.42$. O período da crise da Covid-19 foi onde se registaram os menores valores de correlação com o mercado do Ouro sendo que o maior valor foi do DAX ($\overline{\rho_{ij,t}} = 0.08$).

No que concerne os parâmetros de ajustamento, α e β , que governam de forma comum a evolução da correlação condicional entre os mercados incluídos no modelo, estes mostram-se significativos ao nível de 1%. Estes resultados oferecem evidência contra a hipótese de as correlações condicionais entre os mercados serem constantes, suportando a hipótese das correlações condicionais evidenciarem um comportamento dinâmico ao longo do tempo. Observa-se ainda que a soma dos coeficientes de ajustamento é em todos os períodos superior a 0.85, indicando que o processo descrito pelo modelo para as correlações condicionais evidência uma reversão para a média. A implicação subjacente a esta característica é que, em geral, para os mercados considerados no modelo, após a ocorrência

de um choque, as correlações condicionais nos períodos seguintes tendem para os seus valores não-condicionais de longo prazo.

Os resultados nas tabelas 40, 42 e 44, presentes em apêndice, mostram que para os mercados do continente asiático as somas de α_1 e β_1 são superiores a 0.83, mas inferiores a 1, indicando uma persistência elevada nas variâncias condicionais das variáveis dependentes. Ou seja, os choques na variância condicional tendem a exercer um efeito algo prolongado para, de seguida, os respetivos valores esperados reverterem para os seus valores médios de longo prazo. Os valores médios dos coeficientes de correlação condicionais, $\overline{\rho_{ij,t}}$, especificados na equação (18), e que refletem a correlação não-condicional são significativos. A correlação entre o CSI300 e o Nikkei mais elevada verificou-se no período da crise do Covid-19 ($\overline{\rho_{ij,t}} = 0.32$) e a mais reduzida no período da crise financeira global 2007-2009 ($\overline{\rho_{ij,t}} = 0.22$). Entre o mercado do Brent e os índices, as maiores correlações verificaram-se, para ambos os índices, no período da crise do Covid-19 com CSI300 e Nikkei a apresentar valores de $\overline{\rho_{ij,t}} = 0.17$ e $\overline{\rho_{ij,t}} = 0.18$, respetivamente. Relativamente ao mercado do Ouro, os maiores valores também foram observados durante a crise do Covid-19 com CSI300 e Nikkei a apresentarem valores de $\overline{\rho_{ij,t}} = 0.14$ e $\overline{\rho_{ij,t}} = 0.07$ respetivamente. Entre o Brent e o Ouro, o maior valor de correlação foi observado durante o período da crise financeira global 2007-2009 com $\overline{\rho_{ij,t}} = 0.41$.

No que concerne os parâmetros de ajustamento, α e β , que governam de forma comum a evolução da correção condicional entre os mercados incluídos no modelo, estes mostraram-se significativos ao nível de 1%, com exceção do parâmetro α que no período Covid-19 é significativo ao nível de 10% e no período da crise financeira global 2007-2009 não é significativo. Estes resultados oferecem evidência contra a hipótese de as correlações condicionais entre os mercados serem constantes, suportando a hipótese das correlações condicionais evidenciarem um comportamento dinâmico ao longo do tempo. Observa-se ainda que a soma dos coeficientes de ajustamento é em todos os períodos superior a 0.87, indicando que o processo descrito pelo modelo para as correlações condicionais evidencia uma reversão para a média. A implicação subjacente a esta característica é que, em geral, para os mercados considerados no modelo, após a ocorrência de um choque, as correlações condicionais nos períodos seguintes tendem para os seus valores não-condicionais de longo prazo.


Seria esperado que em alguns casos o Ouro apresentasse uma correlação negativa, pois tal significaria que os investidores pudessem estar a refugiar-se neste ativo, o que validaria a hipótese do Ouro ser percebido pelos investidores como um ativo de cobertura de risco

e de reserva de valor em tempos de incerteza. Porém, as correlações médias condicionais não suportam esta hipótese.

Apesar do Ouro não apresentar uma correlação condicional média negativa, existem subperíodos na crise financeira global 2007-2009, entre o Ouro e o S&P500, em que as correlações condicionais são negativas. A figura 4 apresenta a evolução da variação da correlação condicional entre os mercados financeiros dos países americanos e os mercados do Ouro e do petróleo durante o período da crise financeira global 2007-2009. O gráfico da correlação entre o S&P500 e o Ouro mostra a ocorrência de um período em que a correlação condicional entre os dois ativos foi negativa. Foi entre estes 2 ativos, neste período, que este fenómeno se verificou durante mais tempo e onde atingiu valores mais baixos, levando ao menor valor de correlação condicional média entre um mercado financeiro e o Ouro verificado no estudo ($\overline{\rho_{ij,t}} = 0.015$).

É possível observar nos gráficos de correlação condicional presentes no apêndice H, I e J (figuras 8 a 15), que houve períodos em que momentaneamente a correlação do Ouro com os mercados financeiros esteve em valores negativos, tendo sido um fenómeno muito comum no período da crise da Covid-19 nos países do continente europeu.

Figura 4: Correlações condicionais, DCC-MGARCH, no continente americano (S&P500, TSX, WTI, Ouro) no período da crise financeira global 2007-2009.



4.5. Discussão

Fazendo uma análise dos períodos de crise ao nível regional, é possível observar que no período da crise financeira global 2007-2009 é nos países europeus que se dão as maiores transmissões de risco entre os mercados financeiros e o mercado do petróleo. Já no que diz respeito às transmissões de risco entre os mercados financeiros e o mercado do ouro foi a região americana que apresentou os valores mais baixos, e os maiores valores verificaram-se nos países europeus.

No período da crise da dívida soberana é nos países asiáticos que se observam os menores valores de transmissão de risco com os mercados do Ouro e do petróleo; com a China a apresentar os menores valores relativamente às duas commodities, enquanto os maiores valores se observam nos Estados Unidos da América.

No período Covid-19 foram nos mercados financeiros europeus que se verificaram os menores valores de transmissão com os mercados de *commodities*. Relativamente a ambos os mercados de *commodities*, foi no Japão onde verificaram os maiores valores, tendo os menores sido observados em Itália.

Em todos os períodos de crises financeiras são os países europeus que apresentam maiores correlações condicionais entre os seus mercados financeiros, sendo possível observar o elevado nível de integração entre os mercados da Alemanha e França, que apresentam consistentemente os maiores valores. Os mercados americanos também apresentam valores relativamente altos, mas inferiores aos europeus, demonstrando também a existência de um elevado nível de integração entre os mercados do Canadá e Estados Unidos da América. Pelo contrário, é na região asiática que os países apresentam, consistentemente ao longo dos períodos, as menores correlações condicionais, revelando um baixo nível de integração entre os mercados japonês e chinês.

Relativamente às correlações do mercado do petróleo com os índices bolsistas, os países asiáticos apresentam consistentemente as correlações mais baixas relativamente às outras regiões. Os países europeus e americanos apresentam valores na mesma ordem, não havendo uma região que apresente consistentemente valores mais altos ou mais baixos.

Relativamente às correlações do mercado do Ouro com os índices bolsistas não é possível destacar uma região como tendo os maiores ou menores valores. É no Canadá que os maiores valores da correlação condicional média são verificados, sendo também possível destacar o Japão com valores consistentemente baixos. Não é, no entanto, o país que apresenta os valores mais baixos em todos os períodos.

Foi no período da Covid-19 que a maior parte dos mercados financeiros registou as maiores intensidades de transmissão de risco com o mercado do petróleo, sendo estes resultados consistentes com os obtidos por Jebabli *et al.* (2021), Hung & Vo (2021), Zhang & Hamori (2021). Estes resultados eram esperados dado que as medidas tomadas para combater a propagação da Covid-19 geraram um choque sem precedentes no mercado do petróleo. Os confinamentos sucessivos e as proibições de circulação entre países levaram a que houvesse uma queda acentuada na procura por petróleo, o que provocou um declínio acentuado no seu preço.

Os resultados também indicam que os valores de transmissão de risco entre o petróleo e os índices financeiros são superiores na crise da dívida soberana em comparação com a crise financeira global 2007-2009, o que está em linha com os resultados obtidos por Kang e Yoon (2019), e que pode sugerir uma forte influência da crise financeira global 2007-2009. Já as maiores intensidades de transmissão de informação entre os mercados financeiros e o mercado do Ouro foram verificadas durante a crise financeira global 2007-2009, com exceção do Reino Unido e Estados Unidos, em que a intensidade foi superior durante a crise da dívida soberana, e do Japão que registou a maior intensidade na crise Covid-19.

Em geral é possível observar que as transmissões de risco entre o mercado do Ouro e os índices financeiros apresentam valores inferiores às transmissões entre mercado do petróleo e os índices financeiros, em todos os períodos, o que está em linha com Yaya *et al.* (2016).

Os resultados obtidos referentes à correlação do mercado do Ouro com os mercados acionistas apresentam sinal positivo e significativo, o que leva a rejeitar a hipótese de o Ouro ser classificado como um bom ativo de cobertura de risco em períodos de turbulência financeira. Estes resultados contradizem os estudos que referem que o Ouro tende a agir de forma contra-cíclica a eventos macroeconómicos e a reagir de forma inversa (*i.e.*, apresentando sinal negativo) aos mercados acionistas mantendo ou aumentando o seu valor quando os mesmos desvalorizam (Baur & Lucey, 2010; Beckmann *et al.*, 2015; Elder *et al.*, 2012). O mesmo pode ser dito quando referenciamos estudos mais recentes que analisam as propriedades do Ouro como ativo de cobertura ao risco em países desenvolvidos, como é o caso dos países do G7 e da China, que concluem que o Ouro se constitui como uma boa ferramenta de cobertura ao risco (Ghazali *et al.* 2020; Hussain Shahzad *et al.* 2020). Os resultados deste estudo suportam os obtidos por Akhtaruzzaman *et al.*, (2021), Będowska-Sójka & Kliber (2021), Chemkha *et al.* (2021) e Drake (2022), que não obtiveram evidências de existir correlação negativa entre o Ouro e os mercados acionistas durante períodos de crise, concluindo que o Ouro não possui propriedades de ativo de reserva de valor, podendo não ser um instrumento adequado de cobertura de risco em períodos de crise.

Na correlação do preço do petróleo com o desempenho dos mercados acionistas vimos anteriormente que a literatura não é consensual, havendo vários fatores que podem contribuir para resultados diferentes, mas que os estudos tendem a sugerir uma relação negativa entre os mercados (Rahman, 2021; Miller & Ratti, 2009), tendendo essa relação a ser mais pronunciada em períodos de crise (Rahman & Serletis, 2019). Os resultados obtidos contrariam a hipótese de a relação entre ambos ser negativa pois os valores das correlações médias condicionais, para todos os períodos, em todos os continentes, apresentam sinais positivos, sugerindo que os mercados financeiros e o preço do petróleo sobem e descem em conjunto, estando estes resultados em linha com Ferreira *et al.* (2019).

Um dos fatores que pode influenciar os resultados é o facto de o mercado financeiro que está a ser estudado ser referente a um país importador ou exportador líquido de petróleo. No caso de o estudo incidir sobre um país exportador líquido de petróleo é esperada uma correlação positiva entre os dois mercados devido à preponderância que o petróleo tem nas suas economias (Mokni, 2020; Arouri & Rault, 2012; Alshehri *et al.*, 2017; Sarwar *et al.*, 2018; Nusair & Al-Khasawneh, 2018). No presente estudo temos dois países exportadores líquidos de petróleo, o Canadá e os Estados Unidos da América. O Canadá é um país exportador líquido no período completo enquanto os Estados Unidos da América apenas se tornaram exportadores líquidos durante o período da crise do Covid-19, em 2020. A hipótese de que os países exportadores líquidos de petróleo apresentam correlação positiva com os seus mercados financeiros é suportada com os resultados obtidos neste estudo, apresentando os índices referentes a estes países valores positivos e mais expressivos face aos países importadores líquidos de petróleo, salvo o Reino Unido no período Covid-19 que apresenta um valor idêntico aos países exportadores líquidos de petróleo.

5. Conclusões

Este estudo teve como objetivo geral analisar as transmissões de risco e co-movimentos condicionais entre os mercados financeiros e os mercados de *commodities* (Ouro e Petróleo) durante períodos de crises financeiras, nomeadamente a crise financeira global 2007-2009, a crise da dívida soberana e crise do Covid-19, de forma a compreender as diferenças, em termos de intensidade, entre crises financeiras endógenas e uma crise financeira exógena. Com este objetivo pretendeu-se contribuir para um corpo de literatura ainda relativamente escasso sobre os efeitos gerados pela crise provocada pela Covid-19 nos processos de transmissão de risco e de co-movimentos entre os mercados financeiros e mercados de *commodities*. Além de analisar os padrões de transmissão de risco entre estes mercados durante os períodos de crises financeiras, foram também utilizados procedimentos de análise de co-movimentos, recorrendo às correlações condicionais dinâmicas, para testar a hipótese de o Ouro ser um bom ativo de reserva de valor em tempos de incerteza.

Foram realizados testes de estacionariedade para testar a existência de raízes unitárias nos níveis das séries, que indicaram a não estacionariedade das séries em nível e que levaram à correspondente necessidade de utilizar as variáveis expressas nas primeiras diferenças dos logaritmos nas estimações dos modelos.

O facto de grande parte das séries apresentarem autocorrelações significativas leva a que seja necessário considerar nas equações das médias condicionais dos modelos GARCH, modelos adequados para absorverem a dependência linear existente nas séries dos retornos. Para a seleção dos modelos adequados foram realizados testes de cointegração para averiguar a existência de cointegração entre os níveis das séries, tendo sido considerado o teste de Johansen. Nos casos em que se verificou a existência de cointegração foi adotado o modelo VECM para modelar a média condicional da variável dependente. Nos casos de não-cointegração, optou-se pela utilização do modelo VAR.

Para realizar a análise dos processos de transmissão de risco entre os mercados acionistas e os mercados de *commodities*, mais concretamente os efeitos de co-volatilidade entre os mercados, recorreu-se ao modelo BEKK-diagonal. De forma a examinar os co-movimentos de variações de preços entre os mercados acionistas nacionais e os mercados de *commodities* foi utilizado o modelo DCC-MGARCH para analisar as correlações condicionais dinâmicas.

Os resultados indicam que a crise Covid-19 (de natureza exógena à economia) foi a que apresentou maiores intensidades de transmissão de risco entre os índices financeiros e o

mercados do petróleo comparativamente às crises endógenas. Este resultado era, de certa forma, esperado devido às particularidades da crise Covid-19 em que a economia mundial foi obrigada a estar menos conectada fisicamente e os agentes económicos reduziram as suas movimentações, levando a um declínio tremendo na utilização de meios de transporte, na sua maioria movidos a combustíveis fósseis. Este processo causou um choque sem precedentes na procura de petróleo. Fazendo a comparação entre as crises endógenas, foi na crise da dívida soberana que se deram as maiores transmissões de risco entre os mercados financeiros e o mercado do petróleo. Este resultado deve-se, possivelmente, ao facto desta crise surgir no seguimento da crise financeira global 2007-2009 e os países já estarem de certa forma “debilitados”.

Relativamente às transmissões entre o mercado do Ouro e os índices financeiros, foi durante a crise financeira global 2007-2009 que a maioria dos países verificaram as maiores intensidades de transmissão de risco. Não se observa uma clara diferença nas transmissões de risco entre estes mercados durante a crise da dívida soberana e a crise Covid-19. Os resultados mostram que os níveis de transmissão de risco verificados entre os mercados financeiros e o mercado do petróleo são sempre superiores aos valores verificados entre os mercados financeiros e o mercado do Ouro.

Outro dos objetivos do trabalho era testar a qualidade do mercado do Ouro enquanto ativo de reserva de valor. Esta hipótese foi rejeitada dado que em nenhum período se verificaram correlações condicionais médias negativas entre o Ouro e os mercados financeiros. Este resultado sugere que o Ouro não deve ser visto como um ativo de refúgio e de cobertura de risco em períodos de *stress* financeiro. No entanto, dado que apresenta níveis de transmissão de risco inferiores com os mercados financeiros face ao mercado do petróleo, podemos classificar o Ouro como um ativo com melhores características para diversificação do portefólio em períodos de crise.

Os resultados desta pesquisa contribuem para uma melhor compreensão dos efeitos de transmissão de risco entre o mercado do Ouro, petróleo e dos mercados financeiros em diferentes situações de crise. São de elevado interesse para os vários agentes económicos, incluindo investidores privados e institucionais, gestores de risco, e agentes políticos, que devem estar constantemente a consumir informação sobre transmissão de risco entre os mercados de forma a contruir modelos eficientes de mitigação do risco e a implementar políticas apropriadas em períodos de *stress* financeiro.

No caso das crises endógenas, os governos, principalmente dos países grandes consumidores de petróleo, devem assegurar reservas suficientes do mesmo, para atenuar o *spillover* entre o petróleo e os seus mercados. Assim, as energias renováveis devem

continuar a ser alvo de uma grande aposta por parte dos governos de forma a reduzir a dependência do petróleo, uma fonte de energia com imensuráveis efeitos adversos no meio ambiente e na economia global.

Numa crise exógena, como é o caso da Covid-19, os confinamentos gerais, restrições às viagens, e o encerramento de empresas, por exemplo, aumentam significativamente o risco nos mercados. Os governos devem optar por medidas de contenção que atenuem os efeitos adversos gerados por estes eventos na economia. Devem aplicar medidas de confinamento dinâmicas que entrem em ação apenas em áreas com maior número de casos diários e durante o tempo estritamente necessário ao invés de promover um confinamento nacional e aguardar que a pandemia termine. Este tipo de decisões podem levar à depressão económica. Os países devem focar-se, por exemplo, em medidas que tenham em vista a aceleração da digitalização da economia, promover o comércio digital, agilizar os processos de pagamento removendo ao máximo a necessidade de utilização de formas físicas de pagamentos de forma a estimular a economia.

Esta pesquisa está limitada pela escassez de dados sobre a Covid-19, dado que é uma crise que ainda decorre e cujas repercussões não acabam no final de 2021. Por isso devem continuar a ser levados a cabo estudos envolvendo esta crise com um maior horizonte temporal.

Uma linha de estudo interessante seria analisar as transmissões de risco entre os mercados financeiros e de *commodities* fazendo a comparação entre países que aplicaram medidas severas de combate à Covid-19, nomeadamente na extensão e duração dos confinamentos, e países onde não foram implementadas medidas que impactaram a circulação de pessoas, ou que tiveram uma aplicação muito relaxada dessas medidas. Também seria de valor realizar o estudo apenas para um país/mercado, durante o período Covid-19, analisando individualmente períodos em que o país esteve em confinamento e períodos considerados normais em termos de actividade económica.

6. Bibliografia

- Abuzayed, B., Al-Fayoumi, N., & Bouri, E. (2022). Hedging UK stock portfolios with gold and oil: The impact of Brexit. *Resources Policy*, 75, 102434.
- Akhtaruzzaman, M., Boubaker, S., Lucey, B. M., & Sensoy, A. (2021). Is gold a hedge or a safe-haven asset in the COVID-19 crisis? *Economic Modelling*, 102, 105588
- Albulescu, C. T. (2021). COVID-19 and the United States financial markets' volatility. *Finance Research Letters*, 38, 101699.
- Allen, D. & McAleer, M. (2018). Theoretical and empirical differences between diagonal and full BEKK for risk management. *Energies*, 11(7), 1627.
- Aloui, C., & Jammazi, R. (2010). Wavelet decomposition and regime shifts: Assessing the effects of crude oil shocks on stock market returns. *Energy Policy*, 38 (3), 1415-1435.
- Alshehri, A., Mohanty, S., & Mohanty, S. (2017). Asymmetric effects of oil shocks on stock market returns in Saudi Arabia: evidence from industry level analysis. *Review of Quantitative Finance and Accounting*, 51, 595-619.
- Arouri, M., H., & Nguyen, D., K., (2010). Oil prices, stock markets and portfolio investment: Evidence from sector analysis in Europe over the last decade. *Energy Policy*, 38(8), 4528–4539.
- Arouri, M. E. H. & Rault, C. (2012). Oil prices and stock markets in GCC countries: empirical evidence from panel analysis. *International Journal of Finance and Economics*, 17(3), 242–253.
- Baba, Y., Engle, R., Kraft, D., & Kroner, K. (1990). Multivariate Simultaneous Generalized ARCH. *Unpublished Manuscript*, University of California, San Diego.
- Bagirov, M., & Mateus, C. (2019). Oil prices, stock markets and firm performance: Evidence from Europe. *International Review of Economics and Finance*, 61, 270–288.
- Balcilar, M., Ozdemir, Z. A., & Ozdemir, H. (2021). Dynamic return and volatility spillovers among S&P 500, crude oil, and gold. *International Journal of Finance and Economics*, 26(1), 153–170.
- Barsky, R. & Kilian, L. (2004). Oil and Macroeconomy since the 1970s. *Journal of Economic Perspectives*, 18(4), 115-134.
- Barunik, J. & Krehlik, T. (2018). Measuring the frequency Dynamics of Financial Connectedness and Systemic Risk. *Journal of Financial Econometrics*, 16(2), 271-296

- Basher, S. e Sadorsky, P. (2006). Oil price risk and emerging stock markets. *Global Finance Journal*, 17(2), 224-251.
- Baur, D. G., & Lucey, B. M. (2010). Is Gold a Hedge or a Safe Haven? An Analysis of Stocks, Bonds and Gold. *The Financial Review*, 45(2), 217-229.
- Bauwens, L., Laurent, S. e Rombouts, J. (2006). Multivariate GARCH models: A Survey. *Journal of Applied Econometrics*, 21(1), 79-109.
- Beckmann, J., Berger, T., & Czudaj, R. (2015). Does gold act as a hedge or a safe haven for stocks? A smooth transition approach. *Economic Modelling*, 48, 16–24.
- Będowska-Sójka, B., & Kliber, A. (2021). Is there one safe-haven for various turbulences? The evidence from gold, Bitcoin and Ether. *North American Journal of Economics and Finance*, 56, 101390.
- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31(3), 307–327.
- 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.
- Bollerslev, T., Engle, R. e Wooldridge, J. (1988). A Capital asset pricing model with time varying covariances. *Journal of Political Economy*, 96(1), 116-131.
- Bordo, M. & Haubrich, J. (2017). Deep recessions, fast recoveries, and financial crises: evidence from the american record. *Economic Inquiry*, 55 (1), 527-541.
- Bouhali, H., Dahbani, A., & Dinar, B. (2021). COVID-19 impacts on financial markets: Takeaways from the third wave. *Russian Journal of Economics*, 7(3), 200–212.
- Broadstock, D., Fan, Y., Ji, Q., e Zhang, D. (2016). Shocks and stocks: a bottom-up assessment of the relationship between oil prices, gasoline prices and the returns of chinese firms. *Energy Journal*, 37(1), 55-86.
- Brown, S. e Yucel, M. (2002). Energy prices and aggregate economic activity: an interpretative survey. *Quarterly Review of Economics and Finance*, 42(2), 193-208.
- Çelik, I., Yilmaz, T., & Furkan SAK, A. (2020). *the effects of covid-19 outbreak on financial markets. Financial Studies*, 24(4), 6-28.
- Chang, C., McAleer, M., & Tian, J. (2019). Modeling and testing volatility spillovers in oil and financial markets for the USA, the UK, and China. *Energies*, 12(8), 1475.

- Chemkha, R., BenSaïda, A., Ghorbel, A., & Tayachi, T. (2021). Hedge and safe haven properties during COVID-19: Evidence from Bitcoin and gold. *Quarterly Review of Economics and Finance*, 82, 71–85.
- Degiannakis, S., Filis, G., & Arora, V. (2018). Oil prices and stock markets: A review of the theory and empirical evidence. *Energy Journal*, 39(5), 85–130.
- Dickey, D.A. & Fuller, W.A. (1979). Distribution of the Estimators for Autoregressive Time Series with a Unit Root, *Journal of the American Statistical Association*, 74(366), 427–431.
- Diebold, F. X., & Yilmaz, K. (2012). Better to give than to receive: Predictive directional measurement of volatility *spillovers*. *International Journal of Forecasting*, 28(1), 57–66.
- Diebold, F. X., & Yilmaz, K. (2014). On the network topology of variance decompositions: Measuring the connectedness of financial firms. *Journal of Econometrics*, 182(1), 119–134.
- Drake, P. P. (2022). The gold-stock market relationship during COVID-19. *Finance Research Letters*, 44, 102111.
- Economou, A. (2016). Oil price shocks: A measure of the exogenous and endogenous supply shocks of crude oil. *The Oxford institute for energy studies*.
- Edelstein, P. & Kilian, L. (2009). How sensitive are consumer expenditures to retail energy prices?. *Journal of Monetary Economics*, 56(6), 766-779.
- Elder, J., Miao, H., & Ramchander, S. (2012). Impact of macroeconomic news on metal futures. *Journal of Banking and Finance*, 36(1), 51–65.
- Engle, R. F. & Granger, C. W. J. (1987). Co-integration and error correction: Representation, estimation and testing. *Econometrica*, 55, 251- 276.
- Engle, R. F. & Kroner K. F. (1995). Multivariate Simultaneous Generalized ARCH. *Econometric Review*, 11, 122-150.
- Engle, R. F. (2002). Dynamic conditional correlation: A simple class of multivariate generalized autoregressive conditional heteroskedasticity models. *Journal of Business and Economic Statistics*, 20(3), 339–350.
- Engle, R.F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *The Econometrica*, 50(4), 987–1007.
- Fama, E.F. & French, K.R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, 33(1), 3–56.

- Ferreira, P., Pereira, É. J. de A. L., Silva, M. F. da, & Pereira, H. B. (2019). Detrended correlation coefficients between oil and stock markets: The effect of the 2008 crisis. *Physica A: Statistical Mechanics and Its Applications*, 517, 86–96.
- Filis, G., Degiannakis, S., & Floros, C. (2011). Dynamic correlation between stock market and oil prices: The case of oil-importing and oil-exporting countries. *International Review of Financial Analysis*, 20(3), 152-164.
- Fry-McKibbin, R. A., Hsiao, C. Y., & Tang, C. (2014). Contagion and Global Financial Crises: Lessons from Nine Crisis Episodes. *Open Economics Review*, 25(3), 521–70.
- Ghazali, M. F., Lean, H. H., & Bahari, Z. (2020). Does gold investment offer protection against stock market losses? evidence from five countries. *Singapore Economic Review*, 65(2), 275–301.
- Hamilton, J. (1988). Are the macroeconomic effects of oil-price changes symmetric?: A comment. *Carnegie-Rochester Conference Series on Public Policy*, 28, 369-378.
- Hamilton, J., (1996). This is what happened to the oil price – macroeconomy relationship. *Journal of Monetary Economics*, 38, 215-220.
- Hamilton, J. (2009). Understanding Crude Oil Prices, *Energy Journal*, 30(2), 179-206.
- Hausman, A. & Johnston, W. J. (2014). Timeline of a financial crisis: Introduction to the special issue. *Journal of Business Research*, 67(1), 2667-2670.
- Henriques, I. & Sadorsky, P. (2008). Oil prices and the stock prices of alternative energy companies. *Energy Economics*, 30(3), 998-1010.
- Hoang, T. H., Lahiani, A., & Heller, D. (2016). Is gold a hedge against inflation? New evidence from a nonlinear ARDL approach. *Economic Modelling*, 54, 54–66.
- Hung, N. T., & Vo, X. V. (2021). Directional *spillover* effects and time-frequency nexus between oil, gold and stock markets: Evidence from pre and during COVID-19 outbreak. *International Review of Financial Analysis*, 76, 101730.
- Hussain Shahzad, S. J., Bouri, E., Roubaud, D., & Kristoufek, L. (2020). Safe haven, hedge and diversification for G7 stock markets: Gold versus bitcoin. *Economic Modelling*, 87, 212–224.
- Jebabli, I., Kouaissah, N., & Arouri, M. (2021). Volatility *Spillovers* between Stock and Energy Markets during Crises: A Comparative Assessment between the 2008 Global Financial Crisis and the Covid-19 Pandemic Crisis, *Finance Research Letters*, 102363.

- Johansen, S. (1988). Statistical analysis of cointegration vectors. *Journal of Economic Dynamics and Control*, 12, 231-254.
- Kang, S. H., & Yoon, S. M. (2019). Financial crises and dynamic *spillovers* among Chinese stock and commodity futures markets. *Physica A: Statistical Mechanics and Its Applications*, 531.
- Kang, S., Hernandez, J. A., Sadorsky, P., & McIver, R. (2021). Frequency *spillovers*, connectedness, and the hedging effectiveness of oil and gold for US sector ETFs. *Energy Economics*, 99.
- Kilian, L. (2008). The economic effects of energy price shocks. *Journal of Economic Literature*, 46(4), 871-909.
- Kilian, L. (2009). Not all oil price shocks are alike: disentangling demand and supply Shocks in the crude oil market. *American Economic Review*, 99(3), 1053-1069.
- Kilian, L., Park, C. (2009). The impact of oil price shocks on the US stock market, *International Economic Review*, 50(4), 1267-1287.
- Laborda, R., & Olmo, J. (2021). Volatility *spillover* between economic sectors in financial crisis prediction: Evidence spanning the great financial crisis and Covid-19 pandemic. *Research in International Business and Finance*, 57, 101402.
- Li, Z., Farmanesh, P., Kirikkaleli, D., & Itani, R. (2021). A comparative analysis of COVID-19 and global financial crises: evidence from US economy. *Economic Research-Ekonomska Istrazivanja*, 2427-2441.
- Liao, J., Zhu, X., & Chen, J. (2021). Dynamic *spillovers* across oil, gold and stock markets in the presence of major public health emergencies. *International Review of Financial Analysis*, 77, 101822.
- Liu, Y., Wei, Y., Wang, Q., & Liu, Y. (2022). International stock market risk contagion during the COVID-19 pandemic. *Finance Research Letters*, 45.
- Liu, Z., Ding, Z., Li, R., Jiang, X., Wu, J. S., & Lv, T. (2017). Research on differences of *spillover* effects between international crude oil price and stock markets in China and America. *Natural Hazards*, 88(1), 575-590.
- Lu, H., Paraco, R. (2018). Impact of Oil Price on Australian Stock Market Returns. *Review of Pacific Basin Financial Markets and Policies*, 21 (3), 1850018.

- Maghyereh, A. I., Awartani, B., & Tziogkidis, P. (2017). Volatility spillovers and cross-hedging between gold, oil and equities: Evidence from the Gulf Cooperation Council countries. *Energy Economics*, 68, 440–453.
- McAleer, M., Chan, F., Hoti, S. & Lieberman, O. (2008). Generalized Autoregressive Conditional Correlation. *Econometric Theory*, 24(6), 1554-1583.
- Mccown, J. R., & Zimmerman, J. R. (2006). Is Gold a Zero-Beta Asset? Analysis of the Investment Potential of Precious Metals, *Social Science Research Network Electronic Journal*.
- Mensi, W., Beljid, M., Boubaker, A., & Managi, S. (2013). Correlations and volatility *spillovers* across commodity and stock markets: Linking energies, food, and gold. *Economic Modelling*, 32(1), 15–22.
- Mensi, W., Reboredo, J. C., & Ugolini, A. (2021). Price-switching *spillovers* between gold, oil, and stock markets: Evidence from the USA and China during the COVID-19 pandemic. *Resources Policy*, 73.
- Mensi, W., Yousaf, I., Vo, X. V., & Kang, S. H. (2022). Asymmetric *spillover* and network connectedness between gold, Brent oil and EU subsector markets. *Journal of International Financial Markets, Institutions and Money*, 76.
- Miller, J.I. & Ratti, R.A. (2009). Crude oil and stock markets: Stability, instability, and bubbles. *Energy Economics*, 31(4), 559–568.
- Ming, L., Shen, Y., Yang, S., Zhu, S., & Zhu, H. (2020). Does Gold Serve as a Hedge for the Stock Market in China? Evidence from a Time-Frequency Analysis. *Emerging Markets Finance and Trade*, 56(3), 659–672.
- Mohanty, S. & Nandha, M. (2011). Oil risk exposure: the case of the U.S oil and gas sector. *Financial Review*, 46, (1), 165-191.
- Mokni, K. (2020). Time-varying effect of oil price shocks on the stock market returns: Evidence from oil-importing and oil-exporting countries. *Energy Reports*, (6), 605-619.
- Morema, K., & Bonga-Bonga, L. (2020). The impact of oil and gold price fluctuations on the South African equity market: Volatility *spillovers* and financial policy implications. *Resources Policy*, 68.
- Nusair, S. A., & Al-Khasawneh, J. A. (2018). Oil price shocks and stock market returns of the GCC countries: empirical evidence from quantile regression analysis. *Economic Change and Restructuring*, 51(4), 339–372.

- Phan, D., Sharma, S., & Narayan, P. (2015). Oil price and stock returns of consumers and producers of crude oil. *Journal of International Financial Markets, Institutions and Money*, 40, 1-13.
- Phillips, P.C.B. and Perron, P. (1988). Testing for a Unit Root in Time Series Regression, *Biometrika*, 75(2), 335-346.
- Pindyck, R. (2004). Volatility in natural gas and oil markets, *Journal of Energy and Development*, 30(1), 1-19.
- Rahman, S., & Serletis, A. (2019). Oil Prices and the Stock Markets: Evidence from High Frequency Data. *The Energy Journal*, 40(01).
- Rahman, S. (2021). Oil price volatility and the US stock market. *Empirical Economics*, (61), 1461-1489.
- Rehman, M. U., Kang, S. H., Ahmad, N., & Vo, X. V. (2021). The impact of COVID-19 on the G7 stock markets: A time-frequency analysis. *North American Journal of Economics and Finance*, 58, 101526.
- Sadorsky, P. (1999). Oil prices shocks and stock market activity. *Energy Economics*, 21 (5), 449-469.
- Said, S.E. & Dickey, D.A. (1984). Testing for Unit Roots in Autoregressive-Moving Average Models of Unknown Order. *Biometrika*, 71(3), 599-607.
- Salisu, A. A., Raheem, I. D., & Vo, X. V. (2021). Assessing the safe haven property of the gold market during COVID-19 pandemic. *International Review of Financial Analysis*, 74, 101666
- Sarwar, S., Waheed, R., Wei, C. (2018). Impact of oil prices on firm stock return: industry-wise analysis, *Empirical Economics*, 55, 765–780.
- Sattar, M., Arcilla Jr, F. E., & Fahad Sattar, M. (2020). the response of financial market indices to covid-19 pandemic. *Financial Studies*, 24(3), 83-92.
- Scholtens, B. & Yurtsever, C. (2012). Oil price shocks and European industries. *Energy Economics*, 34(4), 1187–1195.
- Selmi, R., Bouoiyour, J., Miftah, A., & Wohar, M. E. (2021). Managing exposure to volatile oil prices: Evidence from U.S. sectoral and industry-level data. *Resources Policy*, 73, 102143.
- Shaari M, Abdul Rahim, H., Tan, L. (2013). Effects of oil price shocks on the economic sectors in Malaysia. *International Journal Energy Econ Policy*, 3(4), 360–366.

- Thuraisamy, K. S., Sharma, S. S., & Ali Ahmed, H. J. (2013). The relationship between Asian equity and commodity futures markets. *Journal of Asian Economics*, 28, 67–75.
- Wang, Z., Zhang, Z., Zhang, Q., Gao, J., & Lin, W. (2021). COVID-19 and financial market response in China: Micro evidence and possible mechanisms. *PLOS ONE*, 16(9), e0256879.
- Yaya, O. O. S., Tumala, M. M., & Udomboso, C. G. (2016). Volatility persistence and returns *spillovers* between oil and gold prices: Analysis before and after the global financial crisis. *Resources Policy*, 49, 273–281.
- Zhang, D., Hu, M., & Ji, Q. (2020). Financial markets under the global pandemic of COVID-19. *Finance Research Letters*, 36, 101528.
- Zhang, W., & Hamori, S. (2021). Crude oil market and stock markets during the COVID-19 pandemic: Evidence from the US, Japan, and Germany. *International Review of Financial Analysis*, 74, 101702.
- Zhang, Y., Wang, M., Xiong, X., & Zou, G. (2021). Volatility *spillovers* between stock, bond, oil, and gold with portfolio implications: Evidence from China. *Finance Research Letters*, 40, 101786.

7. Apêndices

Apêndice (A) - Histogramas e ajustamentos das funções de densidade dos retornos dos índices accionistas do G7 e da China e das séries do petróleo e do Ouro.

Figura 5: Distribuição dos retornos no período da crise financeira global 2007-2009

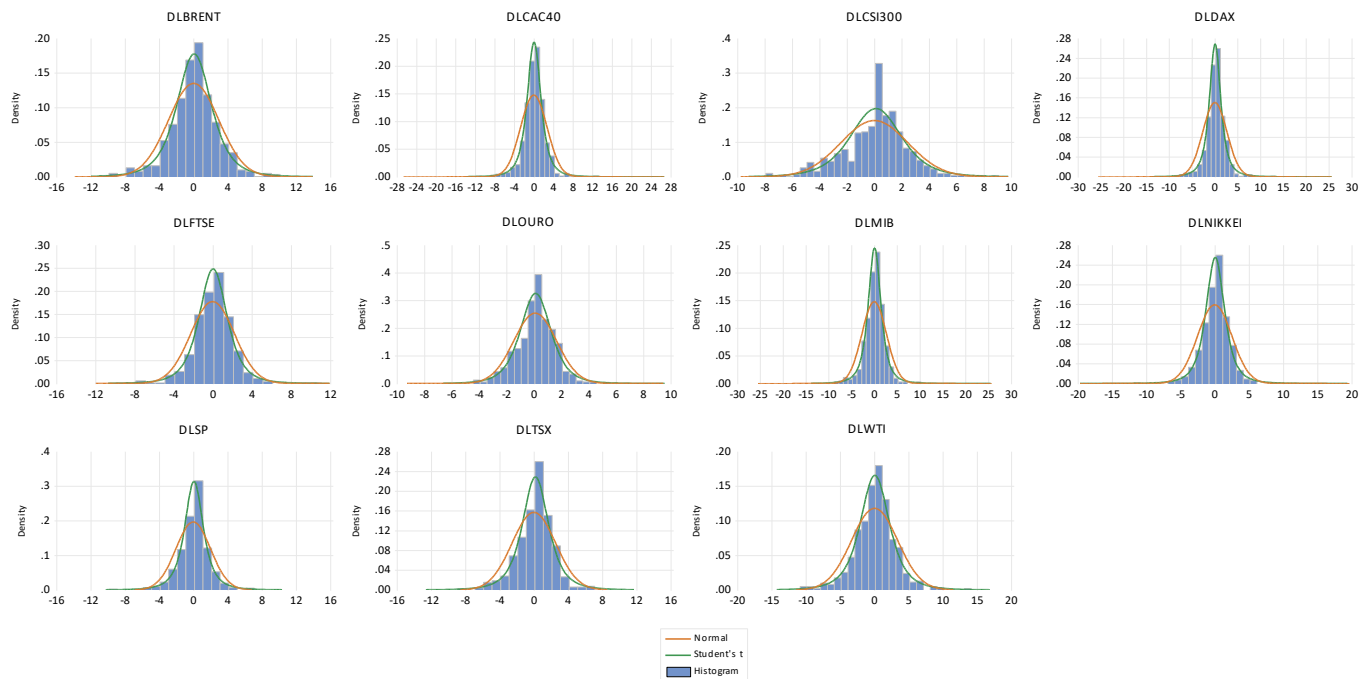


Figura 6: Distribuição dos retornos no período da crise da dívida soberana

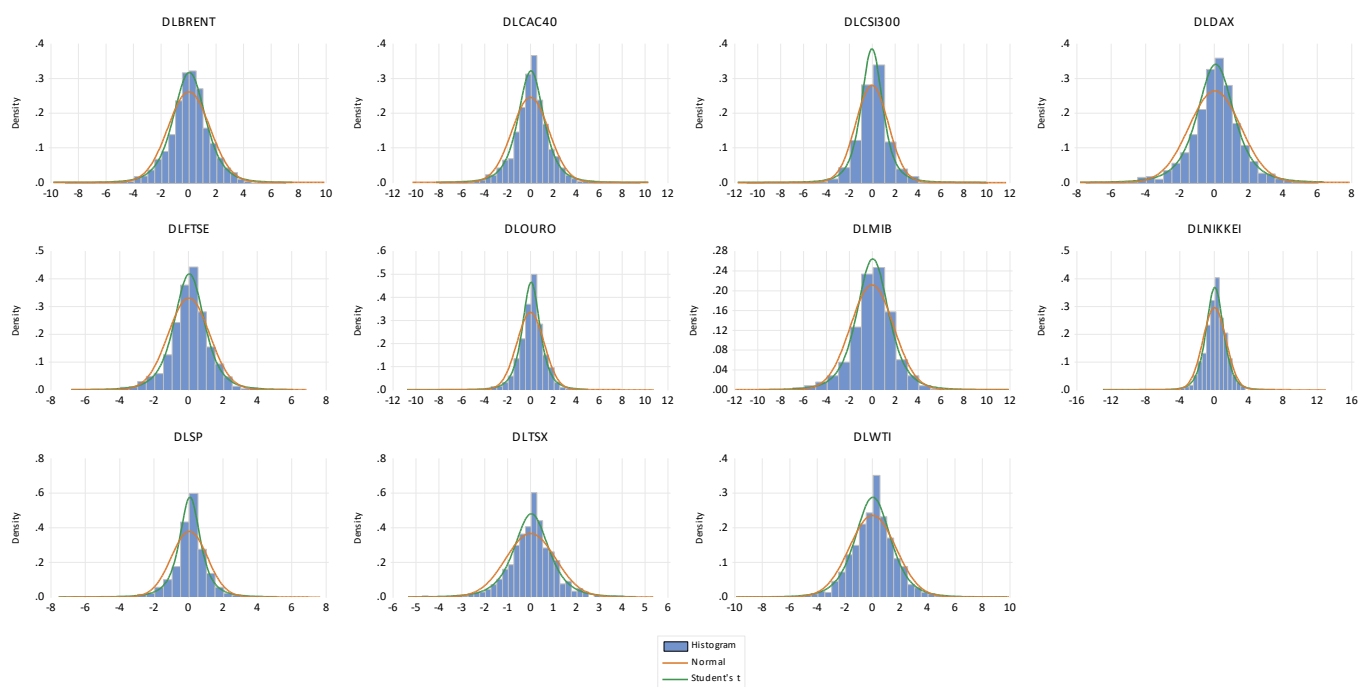
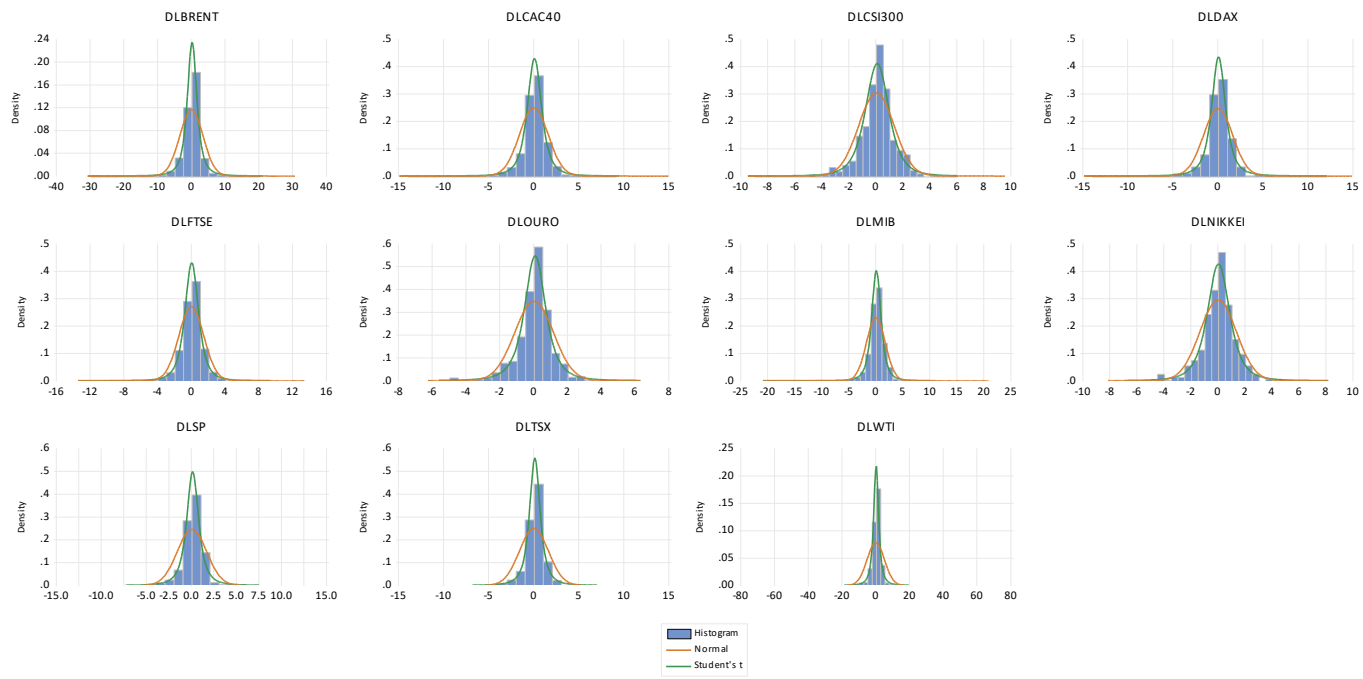


Figura 7: Distribuição dos retornos no período da crise do Covid-19



Apêndice (B) - Outputs do modelo BEKK-Diagonal no período da crise financeira global 2007-2009

Tabela 12: Modelo VECM (1) – BEKK (1,1) – diagonal; CAC40, Brent e Ouro

Equações da média (condicional)	CAC40(t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração (-0.098056**	0.053009	-0.014660
CAC40(t-1)	-0.032994	-0.116790***	0.002020
Brent(t-1)	0.005875	0.031950	0.039425
Ouro(t-1)	0.047158	0.140064*	0.116330**

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
CAC40(t)	0.1196	0.0379	0.0259	0.3017***		0.942***	
Brent(t)		0.0893	0.0237		0.2248***		0.969***
Ouro(t)			0.0279			0.1865***	0.977***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.1196) + (0.3017)^2 \varepsilon_{1,t-1}^2 + (0.942)^2 h_{11,t-1} \\
 h_{22,t} &= (0.0893) + (0.2248)^2 \varepsilon_{2,t-1}^2 + (0.969)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0279) + (0.1865)^2 \varepsilon_{3,t-1}^2 + (0.977)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0379) + (0.3017)(0.2248) \varepsilon_{1,t-1} \varepsilon_{2,t-1} + (0.942)(0.969) h_{12,t-1} \\
 h_{13,t} &= (0.0259) + (0.3017)(0.1865) \varepsilon_{1,t-1} \varepsilon_{3,t-1} + (0.942)(0.977) h_{13,t-1} \\
 h_{23,t} &= (0.0237) + (0.2248)(0.1865) \varepsilon_{2,t-1} \varepsilon_{3,t-1} + (0.969)(0.977) h_{23,t-1}
 \end{aligned}$$

Tabela 13: Modelo VECM (1) – BEKK (1,1) – diagonal; CSI300, Brent e Ouro

Equações da média (condicional)	CSI300 (t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	0.011340	-0.021624	0.016395
CSI300(t-1)	0.042528	-0.086116**	-0.001486
Brent(t-1)	-0.031696	0.026354	0.027064
Ouro (t-1)	0.196309**	0.196541**	0.147708***

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
CSI300(t)	0.3947	0.0453	0.0224	0.308***		0.919***	
Brent(t)		0.0620	0.0233		0.201***		0.976***
Ouro(t)			0.0326			0.181***	0.977***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.3947) + (0.308)^2 \varepsilon_{1,t-1}^2 + (0.919)^2 h_{11,t-1} \\
 h_{22,t} &= (0.0620) + (0.201)^2 \varepsilon_{2,t-1}^2 + (0.976)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0326) + (0.181)^2 \varepsilon_{3,t-1}^2 + (0.977)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0453) + (0.308)(0.201) \varepsilon_{1,t-1} \varepsilon_{2,t-1} + (0.919)(0.976) h_{12,t-1} \\
 h_{13,t} &= (0.0224) + (0.308)(0.181) \varepsilon_{1,t-1} \varepsilon_{3,t-1} + (0.919)(0.977) h_{13,t-1} \\
 h_{23,t} &= (0.0233) + (0.201)(0.181) \varepsilon_{2,t-1} \varepsilon_{3,t-1} + (0.976)(0.977) h_{23,t-1}
 \end{aligned}$$

Tabela 14: Modelo VAR (1) – BEKK (1,1) – diagonal; DAX, Brent e Ouro

Equações da média (condicional)	DAX (t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.080887*	0.080410**	-0.017169
Dax(t-1)	-0.035879	-0.127061***	0.002557
Brent(t-1)	0.030150	0.035169	0.041570
Ouro(t-1)	0.061666	0.148851*	0.114306**

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
DAX (t)	0.0672	0.0218	0.0181	0.278***		0.954***	
Brent(t)		0.0785	0.0214		0.2192***		0.972***
Ouro(t)			0.0278			0.1918***	0.977***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0672) + (0.278)^2 \varepsilon_{1,t-1}^2 + (0.954)^2 h_{11,t-1} \\
 h_{22,t} &= (0.0785) + (0.2192)^2 \varepsilon_{2,t-1}^2 + (0.972)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0278) + (0.1918)^2 \varepsilon_{3,t-1}^2 + (0.977)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0218) + (0.278)(0.2192) \varepsilon_{1,t-1} \varepsilon_{2,t-1} + (0.954)(0.972) h_{12,t-1} \\
 h_{13,t} &= (0.0181) + (0.278)(0.1918) \varepsilon_{1,t-1} \varepsilon_{3,t-1} + (0.954)(0.977) h_{13,t-1} \\
 h_{23,t} &= (0.0214) + (0.2192)(0.1918) \varepsilon_{2,t-1} \varepsilon_{3,t-1} + (0.972)(0.977) h_{23,t-1}
 \end{aligned}$$

Tabela 15: Modelo VECM(1) – BEKK (1,1) – diagonal; FTSE100, Brent e Ouro

Equações da média (condicional)	FTSE100 (t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.073741*	0.017675	-0.006254
FTSE100(t-1)	-0.015323	-0.098301**	-0.001941
Brent(t-1)	0.023152	0.035938	0.046148
Ouro(t-1)	0.033748	0.123891	0.106168**

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
FTSE100 (t)	0.1442	0.0493	0.0272	0.3058***		0.935***	
Brent(t)		0.0801	0.0231		0.2079***		0.973***
Ouro(t)			0.0277			0.1841***	0.977***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.1442) + (0.3058)^2 \varepsilon_{1,t-1}^2 + (0.935)^2 h_{11,t-1} \\
 h_{22,t} &= (0.0801) + (0.2079)^2 \varepsilon_{2,t-1}^2 + (0.973)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0277) + (0.1841)^2 \varepsilon_{3,t-1}^2 + (0.977)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0493) + (0.3058)(0.2079) \varepsilon_{1,t-1} \varepsilon_{2,t-1} + (0.935)(0.973) h_{12,t-1} \\
 h_{13,t} &= (0.0275) + (0.3058)(0.1841) \varepsilon_{1,t-1} \varepsilon_{3,t-1} + (0.935)(0.977) h_{13,t-1} \\
 h_{23,t} &= (0.0231) + (0.2079)(0.1841) \varepsilon_{2,t-1} \varepsilon_{3,t-1} + (0.973)(0.977) h_{23,t-1}
 \end{aligned}$$

Tabela 16: Modelo VAR (1) – BEKK (1,1) – diagonal; MIB, Brent e Ouro

Equações da média (condicional)	MIB(t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.039692	0.037587	-0.011492
MIB(t-1)	-0.060971*	-0.109718**	0.003140
Brent(t-1)	-0.023903	0.031705	0.038058
Ouro(t-1)	0.016222	0.128948	0.110628**

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
MIB (t)	0.1090	0.0312	0.0233	0.3048***		0.942***	
Brent(t)		0.0790	0.0223		0.2204***		0.972***
Ouro(t)			0.0280			0.1831***	0.978***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.1092) + (0.3048)^2 \varepsilon_{1,t-1}^2 + (0.942)^2 h_{11,t-1} \\
 h_{22,t} &= (0.0790) + (0.2204)^2 \varepsilon_{2,t-1}^2 + (0.972)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0280) + (0.1831)^2 \varepsilon_{3,t-1}^2 + (0.978)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0312) + (0.3048)(0.2204) \varepsilon_{1,t-1} \varepsilon_{2,t-1} + (0.942)(0.972) h_{12,t-1} \\
 h_{13,t} &= (0.0233) + (0.3048)(0.1831) \varepsilon_{1,t-1} \varepsilon_{3,t-1} + (0.942)(0.978) h_{13,t-1} \\
 h_{23,t} &= (0.0223) + (0.2204)(0.1831) \varepsilon_{2,t-1} \varepsilon_{3,t-1} + (0.972)(0.978) h_{23,t-1}
 \end{aligned}$$

Tabela 17: Modelo VECM (1) – BEKK (1,1) – diagonal; NIKKEI, Brent e Ouro

Equações da média (condicional)	NIKKEI (t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.247394***	0.027798	0.015260
NIKKEI(t-1)	0.181076***	-0.089955**	-0.002885
Brent(t-1)	-0.116605**	0.043282	0.051876
Ouro(t-1)	-0.016839	0.176792**	0.135169***

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
NIKKEI (t)	0.2140	0.0195	0.0090	0.2536***		0.937***	
Brent(t)		0.0703	0.0248		0.2042***		0.976***
Ouro(t)			0.0310			0.1806***	0.978***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.2140) + (0.2536)^2 \varepsilon_{1,t-1}^2 + (0.937)^2 h_{11,t-1} \\
 h_{22,t} &= (0.0703) + (0.2042)^2 \varepsilon_{2,t-1}^2 + (0.976)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0310) + (0.1806)^2 \varepsilon_{3,t-1}^2 + (0.978)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0195) + (0.2536)(0.2042)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.937)(0.976)h_{12,t-1} \\
 h_{13,t} &= (0.0090) + (0.2536)(0.1806)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.937)(0.978)h_{13,t-1} \\
 h_{23,t} &= (0.0248) + (0.2042)(0.1806)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.976)(0.978)h_{23,t-1}
 \end{aligned}$$

Tabela 18: Modelo VAR (1) – BEKK (1,1) – diagonal; S&P500, WTI e Ouro

Equações da média (condicional)	S&P500(t)	WTI (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.086191**	0.118377**	-0.018760
S&P500(t-1)	-0.018134	-0.056455	0.001913
WTI(t-1)	-0.021823	-0.038634	0.028257
Ouro(t-1)	0.034078	0.136377	0.125655**

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
S&P500 (t)	0.0257	0.0120	0.0068	0.2373***		0.968***	
WTI(t)		0.1068	0.0268		0.2271***		0.969***
Ouro(t)			0.0265			0.1721***	0.979***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0257) + (0.2373)^2 \varepsilon_{1,t-1}^2 + (0.968)^2 h_{11,t-1} \\
 h_{22,t} &= (0.1068) + (0.2271)^2 \varepsilon_{2,t-1}^2 + (0.969)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0265) + (0.1721)^2 \varepsilon_{3,t-1}^2 + (0.979)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0120) + (0.2373)(0.2271)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.968)(0.969)h_{12,t-1} \\
 h_{13,t} &= (0.0068) + (0.2373)(0.1721)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.968)(0.979)h_{13,t-1} \\
 h_{23,t} &= (0.0268) + (0.2271)(0.1721)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.969)(0.979)h_{23,t-1}
 \end{aligned}$$

Tabela 19: Modelo VAR (1) – BEKK (1,1) – diagonal; TSX, WTI e Ouro

Equações da média (condicional)	TSX(t)	WTI (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.072651*	0.071286	0.022105
TSX (t-1)	0.015123	-0.077678*	-0.007023
WTI(t-1)	-0.030038	-0.039094	0.029663
Ouro(t-1)	0.112163	0.176285*	0.133817***

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
TSX (t)	0.1195	0.0534	0.0320	0.2585***		0.955***	
WTI(t)		0.1323	0.0321		0.2297***		0.967***
Ouro(t)			0.0295			0.1792***	0.978***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.1195) + (0.2585)^2 \varepsilon_{1,t-1}^2 + (0.955)^2 h_{11,t-1} \\
 h_{22,t} &= (0.1323) + (0.2297)^2 \varepsilon_{2,t-1}^2 + (0.967)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0295) + (0.1792)^2 \varepsilon_{3,t-1}^2 + (0.978)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0534) + (0.2585)(0.2297) \varepsilon_{1,t-1} \varepsilon_{2,t-1} + (0.955)(0.967) h_{12,t-1} \\
 h_{13,t} &= (0.0320) + (0.2585)(0.1792) \varepsilon_{1,t-1} \varepsilon_{3,t-1} + (0.955)(0.978) h_{13,t-1} \\
 h_{23,t} &= (0.0321) + (0.2297)(0.1792) \varepsilon_{2,t-1} \varepsilon_{3,t-1} + (0.967)(0.978) h_{23,t-1}
 \end{aligned}$$

Tabela 20: Modelo VECM (1) – BEKK (1,1) – diagonal; Ouro, WTI e Brent

Equações da média (condicional)	Ouro(t)	WTI (t)	Brent(t)
(coeficientes Estimados)			
Equação Cointegração	0.000630	0.000623	0.002030*
Ouro (t-1)	0.051838	0.014936	0.029032
WTI(t-1)	0.029175	0.070777	0.079753
Brent(t-1)	-0.035358	-0.143903*	-0.166166**

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
Ouro (t)	4.22E-06	7.04E-06	6.08E-06	0.1721***		0.980***	
WTI(t)		3.41E-05	2.86E-05		0.2538***		0.953***
Brent(t)			2.54E-05			0.2559***	0.957***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (4.22E-06) + (0.1721)^2 \varepsilon_{1,t-1}^2 + (0.980)^2 h_{11,t-1} \\
 h_{22,t} &= (3.41E-05) + (0.2538)^2 \varepsilon_{2,t-1}^2 + (0.953)^2 h_{22,t-1} \\
 h_{33,t} &= (2.54E-05) + (0.2559)^2 \varepsilon_{3,t-1}^2 + (0.957)^2 h_{33,t-1} \\
 h_{12,t} &= (7.04E-06) + (0.1721)(0.2538) \varepsilon_{1,t-1} \varepsilon_{2,t-1} + (0.980)(0.953) h_{12,t-1} \\
 h_{13,t} &= (6.08E-06) + (0.1721)(0.2559) \varepsilon_{1,t-1} \varepsilon_{3,t-1} + (0.980)(0.957) h_{13,t-1} \\
 h_{23,t} &= (2.86E-05) + (0.2538)(0.2559) \varepsilon_{2,t-1} \varepsilon_{3,t-1} + (0.953)(0.957) h_{23,t-1}
 \end{aligned}$$

Apêndice (C) - Outputs do modelo BEKK-Diagonal no período da crise da dívida soberana

Tabela 21: Modelo VECM (1) – BEKK (1,1) – diagonal; CAC40, Brent e Ouro

Equações da média (condicional)	CAC40(t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	0.020882	-0.017722	-0.028114
CAC40(t-1)	0.072893***	-0.000376	0.013502
Brent(t-1)	0.045621	-0.004552	-0.053475*
Ouro(t-1)	0.084459**	0.076015**	0.069398**

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
CAC40(t)	0.0635	0.0342	0.0033	0.2325***		0.960***	
Brent(t)		0.1763	0.0256		0.3048***		0.915***
Ouro(t)			0.0202		0.1623***		0.977***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0635) + (0.2325)^2 \varepsilon_{1,t-1}^2 + (0.960)^2 h_{11,t-1} \\
 h_{22,t} &= (0.1763) + (0.3048)^2 \varepsilon_{2,t-1}^2 + (0.915)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0202) + (0.1623)^2 \varepsilon_{3,t-1}^2 + (0.977)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0342) + (0.2325)(0.3048) \varepsilon_{1,t-1} \varepsilon_{2,t-1} + (0.960)(0.915) h_{12,t-1} \\
 h_{13,t} &= (0.0033) + (0.2325)(0.1623) \varepsilon_{1,t-1} \varepsilon_{3,t-1} + (0.960)(0.977) h_{13,t-1} \\
 h_{23,t} &= (0.0256) + (0.3048)(0.1623) \varepsilon_{2,t-1} \varepsilon_{3,t-1} + (0.915)(0.977) h_{23,t-1}
 \end{aligned}$$

Tabela 22: Modelo VAR (1) – BEKK (1,1) – diagonal; CSI300, Brent e Ouro

Equações da média (condicional)	CSI300 (t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.035991	-0.027885	-0.008464
CSI300(t-1)	0.087543***	-0.022798	-0.003853
Brent(t-1)	0.009654	-0.008291	-0.062250**
Ouro (t-1)	-0.014494	0.088715**	0.062025**

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
CSI300(t)	0.2558	0.0320	0.0059	0.1334***		0.923***	
Brent(t)		0.1565	0.0253		0.3239***		0.919***
Ouro(t)			0.0223			0.1569***	0.978***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.2558) + (0.1334)^2 \varepsilon_{1,t-1}^2 + (0.923)^2 h_{11,t-1} \\
 h_{22,t} &= (0.1565) + (0.3239)^2 \varepsilon_{2,t-1}^2 + (0.919)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0223) + (0.1569)^2 \varepsilon_{3,t-1}^2 + (0.978)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0320) + (0.1334)(0.3239) \varepsilon_{1,t-1} \varepsilon_{2,t-1} + (0.923)(0.919) h_{12,t-1} \\
 h_{13,t} &= (0.0059) + (0.1334)(0.1569) \varepsilon_{1,t-1} \varepsilon_{3,t-1} + (0.923)(0.978) h_{13,t-1} \\
 h_{23,t} &= (0.0223) + (0.3239)(0.1569) \varepsilon_{2,t-1} \varepsilon_{3,t-1} + (0.919)(0.978) h_{23,t-1}
 \end{aligned}$$

Tabela 23: Modelo VAR (1) – BEKK (1,1) – diagonal; DAX, Brent e Ouro

Equações da média (condicional)	DAX (t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	0.078273**	-0.007472	-0.023856
Dax(t-1)	0.065009**	-0.011585	0.011230
Brent(t-1)	0.055150	-0.001144	-0.047975*
Ouro(t-1)	0.113703***	0.077587**	0.068310**

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
DAX (t)	0.0427	0.0276	0.0035	0.2402***		0.961***	
Brent(t)		0.1823	0.0261		0.3035***		0.913***
Ouro(t)			0.0231			0.1651***	0.976***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0427) + (0.2402)^2 \varepsilon_{1,t-1}^2 + (0.961)^2 h_{11,t-1} \\
 h_{22,t} &= (0.1823) + (0.3035)^2 \varepsilon_{2,t-1}^2 + (0.913)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0231) + (0.1651)^2 \varepsilon_{3,t-1}^2 + (0.976)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0276) + (0.2402)(0.3035) \varepsilon_{1,t-1} \varepsilon_{2,t-1} + (0.961)(0.913) h_{12,t-1} \\
 h_{13,t} &= (0.0035) + (0.2402)(0.1651) \varepsilon_{1,t-1} \varepsilon_{3,t-1} + (0.961)(0.976) h_{13,t-1} \\
 h_{23,t} &= (0.0261) + (0.3035)(0.1651) \varepsilon_{2,t-1} \varepsilon_{3,t-1} + (0.913)(0.976) h_{23,t-1}
 \end{aligned}$$

Tabela 24: Modelo VAR (1) – BEKK (1,1) – diagonal; FTSE100, Brent e Ouro

Equações da média (condicional)	FTSE100 (t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.013117	0.054547	-0.053759*
FTSE100(t-1)	0.127322***	-0.024512	0.034071
Brent(t-1)	0.029591	0.004148	-0.034168
Ouro(t-1)	0.017584	0.030705	0.007322

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
FTSE100 (t)	0.0396	0.0539	0.0085	0.2543***		0.952***	
Brent(t)		0.3757	0.0427		0.4144***		0.821***
Ouro(t)			0.0575			0.2921***	0.937***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0396) + (0.2543)^2 \varepsilon_{1,t-1}^2 + (0.952)^2 h_{11,t-1} \\
 h_{22,t} &= (0.3757) + (0.4144)^2 \varepsilon_{2,t-1}^2 + (0.821)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0575) + (0.2921)^2 \varepsilon_{3,t-1}^2 + (0.937)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0539) + (0.2543)(0.4144)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.952)(0.821)h_{12,t-1} \\
 h_{13,t} &= (0.0085) + (0.2543)(0.2921)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.952)(0.937)h_{13,t-1} \\
 h_{23,t} &= (0.0427) + (0.4144)(0.2921)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.821)(0.937)h_{23,t-1}
 \end{aligned}$$

Tabela 25: Modelo VAR (1) – BEKK (1,1) – diagonal; MIB, Brent e Ouro

Equações da média (condicional)	MIB(t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	0.030953	-0.023883	-0.028725*
MIB(t-1)	0.090625***	0.005900	0.014263
Brent(t-1)	0.008471	-0.012172	-0.053133*
Ouro(t-1)	0.060862	0.086750**	0.066864**

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
MIB (t)	0.0842	0.0346	0.0044	0.2248***		0.963***	
Brent(t)		0.1496	0.0231		0.2988***		0.923***
Ouro(t)			0.0221			0.1665***	0.976***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0842) + (0.2248)^2 \varepsilon_{1,t-1}^2 + (0.963)^2 h_{11,t-1} \\
 h_{22,t} &= (0.1496) + (0.2988)^2 \varepsilon_{2,t-1}^2 + (0.923)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0221) + (0.1665)^2 \varepsilon_{3,t-1}^2 + (0.976)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0346) + (0.2248)(0.2988)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.963)(0.923)h_{12,t-1} \\
 h_{13,t} &= (0.0044) + (0.2248)(0.1665)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.963)(0.976)h_{13,t-1} \\
 h_{23,t} &= (0.0231) + (0.2988)(0.1665)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.923)(0.976)h_{23,t-1}
 \end{aligned}$$

Tabela 26: Modelo VAR (1) – BEKK (1,1) – diagonal; NIKKEI, Brent e Ouro

Equações da média (condicional)	NIKKEI (t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.181256***	-0.035828	-0.003799
NIKKEI(t-1)	0.163882***	-0.016190	0.001007
Brent(t-1)	0.030477	-0.004537	-0.073552**
Ouro(t-1)	0.074825**	0.090727**	0.058424*

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
NIKKEI (t)	0.0779	0.0062	0.0015	0.1969***		0.956***	
Brent(t)		0.0975	0.0141		0.2481***		0.949***
Ouro(t)			0.0171			0.1403***	0.982***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0779) + (0.1969)^2 \varepsilon_{1,t-1}^2 + (0.956)^2 h_{11,t-1} \\
 h_{22,t} &= (0.0975) + (0.2481)^2 \varepsilon_{2,t-1}^2 + (0.949)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0171) + (0.1403)^2 \varepsilon_{3,t-1}^2 + (0.982)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0062) + (0.1969)(0.2481)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.956)(0.949)h_{12,t-1} \\
 h_{13,t} &= (0.0015) + (0.1969)(0.1403)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.956)(0.982)h_{13,t-1} \\
 h_{23,t} &= (0.0141) + (0.2481)(0.1403)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.949)(0.982)h_{23,t-1}
 \end{aligned}$$

Tabela 27: Modelo VAR (1) – BEKK (1,1) – diagonal; S&P500, WTI e Ouro

Equações da média (condicional)	S&P500(t)	WTI (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.105897***	0.078448	0.015035
S&P500(t-1)	0.043947***	-0.019537	0.015720
WTI(t-1)	-0.019220	-0.029765	-0.039904
Ouro(t-1)	0.051345**	0.015019	0.006254

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
S&P500 (t)	0.0334	0.0667	0.0050	0.3456***		0.922***	
WTI(t)		0.5081	0.0538		0.4179***		0.809***
Ouro(t)			0.0578			0.2871***	0.938***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0334) + (0.3456)^2 \varepsilon_{1,t-1}^2 + (0.922)^2 h_{11,t-1} \\
 h_{22,t} &= (0.5081) + (0.4179)^2 \varepsilon_{2,t-1}^2 + (0.809)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0578) + (0.2871)^2 \varepsilon_{3,t-1}^2 + (0.938)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0667) + (0.3456)(0.4179)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.922)(0.809)h_{12,t-1} \\
 h_{13,t} &= (0.0050) + (0.3456)(0.2871)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.922)(0.938)h_{13,t-1} \\
 h_{23,t} &= (0.0538) + (0.4179)(0.2871)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.809)(0.938)h_{23,t-1}
 \end{aligned}$$

Tabela 28: Modelo VAR (1) – BEKK (1,1) – diagonal; TSX, WTI e Ouro

Equações da média (condicional)	TSX(t)	WTI (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	0.048152	0.056230	0.062712**
TSX (t-1)	0.099584***	-0.030848	-0.006021
WTI(t-1)	0.010350	-0.033851	-0.077426**
Ouro(t-1)	0.058986**	0.082913*	0.053867*

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
TSX (t)	0.0208	0.0185	0.0067	0.2328***		0.963***	
WTI(t)		0.1199	0.0191		0.2325***		0.951***
Ouro(t)			0.0203			0.1482***	0.979***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0208) + (0.2328)^2 \varepsilon_{1,t-1}^2 + (0.963)^2 h_{11,t-1} \\
 h_{22,t} &= (0.1199) + (0.2325)^2 \varepsilon_{2,t-1}^2 + (0.951)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0203) + (0.1482)^2 \varepsilon_{3,t-1}^2 + (0.979)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0185) + (0.2328)(0.2325)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.963)(0.951)h_{12,t-1} \\
 h_{13,t} &= (0.0067) + (0.2328)(0.1482)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.963)(0.979)h_{13,t-1} \\
 h_{23,t} &= (0.0191) + (0.2325)(0.1482)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.951)(0.979)h_{23,t-1}
 \end{aligned}$$

Tabela 29: Modelo VAR (1) – BEKK (1,1) – diagonal; Ouro, WTI e Brent

Equações da média (condicional)	Ouro(t)	WTI (t)	Brent(t)
(coeficientes Estimados)			
Equação Cointegração	-0.040311	-0.033173	0.002955
Ouro (t-1)	0.025779	0.005915	0.038123
WTI(t-1)	-0.006920	0.000109	-0.040795
Brent(t-1)	0.007002	0.018277	0.031690

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
Ouro (t)	0.0578	0.0544	0.0433	0.2869***		0.939***	
WTI(t)		0.5190	0.3768		0.4240***		0.804***
Brent(t)			0.3914			0.4184***	0.816***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0575) + (0.2869)^2 \varepsilon_{1,t-1}^2 + (0.939)^2 h_{11,t-1} \\
 h_{22,t} &= (0.5190) + (0.4240)^2 \varepsilon_{2,t-1}^2 + (0.804)^2 h_{22,t-1} \\
 h_{33,t} &= (0.3914) + (0.4184)^2 \varepsilon_{3,t-1}^2 + (0.816)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0544) + (0.2869)(0.4240)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.939)(0.804)h_{12,t-1} \\
 h_{13,t} &= (0.0433) + (0.2869)(0.4184)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.939)(0.816)h_{13,t-1} \\
 h_{23,t} &= (0.3768) + (0.4240)(0.4184)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.804)(0.816)h_{23,t-1}
 \end{aligned}$$

Apêndice (D) - Outputs do modelo BEKK-Diagonal no período da crise da Covid-19

Tabela 30: Modelo VAR (1) – BEKK (1,1) – diagonal; CAC40, Brent e Ouro

Equações da média (condicional)	CAC40(t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.021010	0.122892	0.015665
CAC40(t-1)	0.008337	-0.024283	0.005058
Brent(t-1)	0.178289***	-0.005275	-0.032609
Ouro(t-1)	0.098795**	0.255058***	0.109693***

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
CAC40(t)	0.0449	0.0467	0.0023	0.2102***		0.966***	
Brent(t)		0.2972	-0.0060		0.3611***		0.919***
Ouro(t)			0.0742			0.1614***	0.957***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0449) + (0.2102)^2 \varepsilon_{1,t-1}^2 + (0.966)^2 h_{11,t-1} \\
 h_{22,t} &= (0.2972) + (0.3611)^2 \varepsilon_{2,t-1}^2 + (0.919)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0742) + (0.1614)^2 \varepsilon_{3,t-1}^2 + (0.957)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0467) + (0.2102)(0.3611)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.966)(0.919)h_{12,t-1} \\
 h_{13,t} &= (0.0023) + (0.2102)(0.1614)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.966)(0.957)h_{13,t-1} \\
 h_{23,t} &= (-0.0060) + (0.3611)(0.1614)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.919)(0.957)h_{23,t-1}
 \end{aligned}$$

Tabela 31: Modelo VAR (1) – BEKK (1,1) – diagonal; CSI300, Brent e Ouro

Equações da média (condicional)	CSI300 (t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.023124	0.072920	-0.012307
CSI300(t-1)	0.013370	0.037995	0.014514
Brent(t-1)	0.190598***	-0.044665	-0.001762
Ouro (t-1)	0.099767**	0.200996**	0.100441**

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
CSI300(t)	0.2961	0.0505	0.0156	0.2137***		0.885***	
Brent(t)		0.2967	-0.0062		0.3461***		0.922***
Ouro(t)			0.0497			0.1691***	0.965***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.2961) + (0.2137)^2 \varepsilon_{1,t-1}^2 + (0.885)^2 h_{11,t-1} \\
 h_{22,t} &= (0.2967) + (0.3461)^2 \varepsilon_{2,t-1}^2 + (0.922)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0497) + (0.1691)^2 \varepsilon_{3,t-1}^2 + (0.965)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0505) + (0.2137)(0.3461)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.885)(0.922)h_{12,t-1} \\
 h_{13,t} &= (0.0156) + (0.2137)(0.1691)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.885)(0.965)h_{13,t-1} \\
 h_{23,t} &= (-0.0062) + (0.3461)(0.1691)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.922)(0.965)h_{23,t-1}
 \end{aligned}$$

Tabela 32: Modelo VECM (1) – BEKK (1,1) – diagonal; DAX, Brent e Ouro

Equações da média (condicional)	DAX (t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.005063	0.048773**	0.018218**
Dax(t-1)	-0.087737**	0.043176	-0.002739
Brent(t-1)	0.030121*	0.005672	0.012155
Ouro(t-1)	0.229344***	0.016255	-0.022592

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
DAX (t)	2.02E-06	3.75E-06	3.89E-07	0.1791***		0.977***	
Brent(t)		3.27E-05	-4.37E-07		0.3498***		0.919***
Ouro(t)			7.85E-06			0.1869***	0.952***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (2.02E - 06) + (0.1791)^2 \varepsilon_{1,t-1}^2 + (0.977)^2 h_{11,t-1} \\
 h_{22,t} &= (3.27E - 05) + (0.3498)^2 \varepsilon_{2,t-1}^2 + (0.919)^2 h_{22,t-1} \\
 h_{33,t} &= (7.85E - 06) + (0.1869)^2 \varepsilon_{3,t-1}^2 + (0.952)^2 h_{33,t-1} \\
 h_{12,t} &= (3.75E - 06) + (0.1791)(0.3498)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.977)(0.919)h_{12,t-1} \\
 h_{13,t} &= (3.89E - 07) + (0.1791)(0.1869)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.977)(0.952)h_{13,t-1} \\
 h_{23,t} &= (-4.37E - 07) + (0.3498)(0.1869)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.919)(0.952)h_{23,t-1}
 \end{aligned}$$

Tabela 33: Modelo VAR (1) – BEKK (1,1) – diagonal; FTSE100, Brent e Ouro

Equações da média (condicional)	FTSE100 (t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.064062	0.068151	-0.005880
FTSE100(t-1)	0.032644*	-0.012279	0.014691
Brent(t-1)	0.172079***	-0.040931	-0.030189
Ouro(t-1)	0.051286	0.252998***	0.105090***

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
FTSE100(t-1)	0.0134	0.0491	0.0030	0.1577***		0.983***	
Brent(t-1)		0.3118	-0.0035		0.3495***		0.917***
Ouro(t-1)			0.0867			0.1729***	0.949***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0134) + (0.1577)^2 \varepsilon_{1,t-1}^2 + (0.983)^2 h_{11,t-1} \\
 h_{22,t} &= (0.3118) + (0.3495)^2 \varepsilon_{2,t-1}^2 + (0.917)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0867) + (0.1729)^2 \varepsilon_{3,t-1}^2 + (0.949)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0491) + (0.1577)(0.3495)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.983)(0.917)h_{12,t-1} \\
 h_{13,t} &= (0.0030) + (0.1577)(0.1729)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.983)(0.949)h_{13,t-1} \\
 h_{23,t} &= (-0.0867) + (0.3495)(0.1729)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.917)(0.949)h_{23,t-1}
 \end{aligned}$$

Tabela 34: Modelo VAR (1) – BEKK (1,1) – diagonal; MIB, Brent e Ouro

Equações da média (condicional)	MIB(t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.058828	0.104782	0.010862
MIB(t-1)	0.020471	-0.032624	0.008091
Brent(t-1)	0.140906***	-0.030458	-0.037888
Ouro(t-1)	0.125096***	0.244629***	0.122339***

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
MIB (t)	0.0341	0.0512	0.0039	0.1384***		0.981***	
Brent(t)		0.2665	-0.0037		0.3374***		0.927***
Ouro(t)			0.0686			0.1674***	0.959***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0341) + (0.1384)^2 \varepsilon_{1,t-1}^2 + (0.981)^2 h_{11,t-1} \\
 h_{22,t} &= (0.2665) + (0.3374)^2 \varepsilon_{2,t-1}^2 + (0.927)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0686) + (0.1674)^2 \varepsilon_{3,t-1}^2 + (0.959)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0512) + (0.1384)(0.3374)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.981)(0.927)h_{12,t-1} \\
 h_{13,t} &= (0.0039) + (0.1384)(0.1674)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.981)(0.959)h_{13,t-1} \\
 h_{23,t} &= (-0.0037) + (0.3374)(0.1674)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.927)(0.959)h_{23,t-1}
 \end{aligned}$$

Tabela 35: Modelo VAR (1) – BEKK (1,1) – diagonal; NIKKEI, Brent e Ouro

Equações da média (condicional)	NIKKEI (t)	Brent (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.170734***	-0.026706	-0.030320
NIKKEI(t-1)	0.062849***	0.040328	0.011659
Brent(t-1)	0.092141**	-0.016916	-0.011578
Ouro(t-1)	0.075859*	0.245253***	0.116875***

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
NIKKEI (t)	0.8481	0.1983	-0.0006	0.5747***		0.463***	
Brent(t)		0.3065	-0.0018		0.3364***		0.923***
Ouro(t)			0.0608			0.1609***	0.962***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.8481) + (0.5747)^2 \varepsilon_{1,t-1}^2 + (0.463)^2 h_{11,t-1} \\
 h_{22,t} &= (0.3065) + (0.3364)^2 \varepsilon_{2,t-1}^2 + (0.923)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0608) + (0.1609)^2 \varepsilon_{3,t-1}^2 + (0.962)^2 h_{33,t-1} \\
 h_{12,t} &= (0.1983) + (0.5747)(0.3364) \varepsilon_{1,t-1} \varepsilon_{2,t-1} + (0.463)(0.923) h_{12,t-1} \\
 h_{13,t} &= (-0.0006) + (0.5747)(0.1609) \varepsilon_{1,t-1} \varepsilon_{3,t-1} + (0.463)(0.962) h_{13,t-1} \\
 h_{23,t} &= (-0.0018) + (0.3364)(0.1609) \varepsilon_{2,t-1} \varepsilon_{3,t-1} + (0.923)(0.962) h_{23,t-1}
 \end{aligned}$$

Tabela 36: Modelo VAR (1) – BEKK (1,1) – diagonal; S&P500, WTI e Ouro

Equações da média (condicional)	S&P500(t)	WTI (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	-0.139088***	0.043046	-0.008334
S&P500(t-1)	-0.015990	-0.033309	0.005656
WTI(t-1)	0.040114	-0.068873	-0.026997
Ouro(t-1)	0.179044***	0.290938***	0.112046***

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
S&P500 (t)	0.0702	0.0742	0.0053	0.4339***		0.902***	
WTI(t)		0.6215	0.0026		0.3429***		0.907***
Ouro(t)			0.0364			0.1265***	0.979***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0702) + (0.4339)^2 \varepsilon_{1,t-1}^2 + (0.902)^2 h_{11,t-1} \\
 h_{22,t} &= (0.6215) + (0.3429)^2 \varepsilon_{2,t-1}^2 + (0.907)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0364) + (0.1265)^2 \varepsilon_{3,t-1}^2 + (0.979)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0742) + (0.4339)(0.3429) \varepsilon_{1,t-1} \varepsilon_{2,t-1} + (0.902)(0.907) h_{12,t-1} \\
 h_{13,t} &= (0.0053) + (0.4339)(0.1265) \varepsilon_{1,t-1} \varepsilon_{3,t-1} + (0.902)(0.979) h_{13,t-1} \\
 h_{23,t} &= (0.0026) + (0.3429)(0.1265) \varepsilon_{2,t-1} \varepsilon_{3,t-1} + (0.907)(0.979) h_{23,t-1}
 \end{aligned}$$

Tabela 37: Modelo VAR (1) – BEKK (1,1) – diagonal; TSX, WTI e Ouro

Equações da média (condicional)	TSX(t)	WTI (t)	Ouro(t)
(coeficientes Estimados)			
Equação Cointegração	0.077915*	0.144151	-0.028701
TSX (t-1)	0.031125**	-0.071926*	0.008390
WTI(t-1)	0.067530**	-0.131447	-0.026099
Ouro(t-1)	0.116875***	0.279264***	0.113495***

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
TSX (t)	0.0542	0.0701	0.0080	0.3665***		0.921***	
WTI(t)		0.5310	0.0010		0.3295***		0.911***
Ouro(t)			0.0357			0.1179***	0.979***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0542) + (0.3665)^2 \varepsilon_{1,t-1}^2 + (0.921)^2 h_{11,t-1} \\
 h_{22,t} &= (0.5510) + (0.3295)^2 \varepsilon_{2,t-1}^2 + (0.911)^2 h_{22,t-1} \\
 h_{33,t} &= (0.0357) + (0.1179)^2 \varepsilon_{3,t-1}^2 + (0.979)^2 h_{33,t-1} \\
 h_{12,t} &= (0.0701) + (0.3665)(0.3295)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.921)(0.911)h_{12,t-1} \\
 h_{13,t} &= (0.0080) + (0.3665)(0.1179)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.921)(0.979)h_{13,t-1} \\
 h_{23,t} &= (0.0010) + (0.3295)(0.1179)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.911)(0.979)h_{23,t-1}
 \end{aligned}$$

Tabela 38: Modelo VECM (1) – BEKK (1,1) – diagonal; Ouro, WTI e Brent

Equações da média (condicional)	Ouro(t)	WTI (t)	Brent(t)
(coeficientes Estimados)			
Equação Cointegração	-0.012558	-0.119108	-0.069613
Ouro (t-1)	-0.025367	-0.247348***	-0.080307
WTI(t-1)	0.047820	0.276704***	0.121990
Brent(t-1)	0.095707**	0.270191***	0.249031***

Equações das variâncias-covariâncias (condicionais)	Matriz M			Matriz A		Matriz B	
BEKK(1,1)-Diagonal							
Ouro (t)	0.0713	-0.0059	-0.0085	0.1269***		0.969***	
WTI(t)		0.9611	0.7924		0.4192***		0.870***
Brent(t)			0.6937			0.406***	0.886***

Equações de variâncias-covariâncias condicionais:

$$\begin{aligned}
 h_{11,t} &= (0.0713) + (0.1269)^2 \varepsilon_{1,t-1}^2 + (0.969)^2 h_{11,t-1} \\
 h_{22,t} &= (0.9611) + (0.4192)^2 \varepsilon_{2,t-1}^2 + (0.870)^2 h_{22,t-1} \\
 h_{33,t} &= (0.6937) + (0.406)^2 \varepsilon_{3,t-1}^2 + (0.886)^2 h_{33,t-1} \\
 h_{12,t} &= (-0.0059) + (0.1269)(0.4192)\varepsilon_{1,t-1}\varepsilon_{2,t-1} + (0.969)(0.870)h_{12,t-1} \\
 h_{13,t} &= (-0.0085) + (0.1269)(0.406)\varepsilon_{1,t-1}\varepsilon_{3,t-1} + (0.969)(0.886)h_{13,t-1} \\
 h_{23,t} &= (0.7924) + (0.4192)(0.406)\varepsilon_{2,t-1}\varepsilon_{3,t-1} + (0.870)(0.886)h_{23,t-1}
 \end{aligned}$$

Apêndice (E) - Outputs do modelo DCC-MGARCH no período da crise da Covid-19

Tabela 39: Estimação do Modelo VECM(1) - DCC-MGARCH(1,1) para os mercados acionistas Europeus e os mercados de *commodities* (CAC40, DAX, FTSE100, MIB, Brent, Ouro)

	CAC40	DAX	FTSE100	MIB	Brent	Ouro
Painel A - Equações da média condicional						
Coint. Eq.	-0.01	-0.01	9.88E-05	0.005	0.09***	0.009
CAC40(-1)	-0.06	0.16	0.02	0.02	-0.63*	0.11
DAX(-1)	0.04	0.07	0.22*	-0.01	-0.08	-0.14
FTSE(-1)	0.13	0.12	-0.04	0.15	0.18	-0.002
MIB(-1)	-0.11	-0.07	-0.18*	-0.23**	0.19	0.05
Brent(-1)	0.04*	0.05**	0.04*	0.05**	0.18***	0.002
Ouro(-1)	0.16**	0.18***	0.17***	0.14**	0.13	0.02
Painel B - Equações da variância condicional						
$h_{ii,t} = \omega_0 + \alpha_1 \varepsilon_{i,t-1}^2 + \beta_1 h_{ii,t-1}$						
ω_0	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
α_1	0.2014***	0.1677***	0.1118***	0.2166***	0.2148***	0.1195***
β_1	0.7442***	0.7997***	0.8537***	0.7566***	0.7667***	0.7666***
Painel C - Correlações médias condicionais ($\overline{\rho_{ij,t}}$)						
CAC		0.9145***	0.8513***	0.9022***	0.3947***	0.0262***
DAX			0.8093***	0.8882***	0.3355***	0.0802***
FTSE				0.7902***	0.4005***	0.0707***
MIB					0.3929***	0.0527***
Brent						0.0406***
Coeficientes de ajustamento do processo de correlação condicional						
$\alpha = 0.0275***$ (lambda 1)						
$\beta = 0.8260***$ (lambda 2)						

Tabela 40: Estimação do Modelo VECM(1) - DCC-MGARCH(1,1) para os mercados acionistas Asiáticos e os mercados de *commodities* (CSI300, NIKKEI, Brent, Ouro)

	CSI300	NIKKEI	Brent	Ouro
Painel A - Equações da média condicional				
Coint. Eq.	-0.04***	-0.01	-0.08***	0.02***
CSI300(-1)	0.04	-0.04	0.12	-0.02
NIKKEI(-1)	-0.08*	-0.07	-0.25**	0.03
Brent(-1)	0.02	0.03**	0.10**	0.01
Ouro(-1)	0.19***	0.29***	0.03	0.02
Painel B - Equações da variância condicional				
$h_{ii,t} = \omega_0 + \alpha_1 \varepsilon_{i,t-1}^2 + \beta_1 h_{ii,t-1}$				
ω_0	0.0000	0.0000	0.0000	0.0000
α_1	0.0037***	0.2085***	0.1978**	0.1196***
β_1	0.9950***	0.6522***	0.7977***	0.7683***
Painel C - Correlações médias condicionais ($\overline{\rho_{ij,t}}$)				
CSI300		0.3170***	0.1692***	0.1424***
NIKKEI			0.1768***	0.0701***
Brent				0.0381***
Coeficientes de ajustamento do processo de correlação condicional				
$\alpha = 0.0191*$ (lambda 1)				
$\beta = 0.8592***$ (lambda 2)				

Apêndice (F) - Outputs do modelo DCC-MGARCH no período da crise da dívida soberana

Tabela 41: Estimação do Modelo VAR(1) - DCC-MGARCH(1,1) para os mercados acionistas Europeus e o mercado de *commodities* (CAC40, DAX, FTSE100, MIB, Brent, Ouro)

	CAC40	DAX	FTSE100	MIB	Brent	Ouro
Painel A - Equações da média condicional						
Const.	-0.002	0.03	0.01	-0.03	0.02	0.01
CAC40(-1)	-0.2*	-0.18	-0.15*	-0.20	0.05	0.01
DAX(-1)	0.21**	0.29***	0.28***	0.21*	0.08	0.02
FTSE100(-1)	-0.17**	-0.14*	-0.21***	-0.15*	0.04	-0.09*
MIB(-1)	0.18***	0.09*	0.08	0.17**	-0.11*	0.01
Brent(-1)	0.14***	0.15***	0.12***	0.15***	-0.02	0.03
Ouro(-1)	3.78E-4	-0.02	0.03	-0.05	0.002	-0.03
Painel B - Equações da variância condicional						
$h_{ii,t} = \omega_0 + \alpha_1 \varepsilon_{i,t-1}^2 + \beta_1 h_{ii,t-1}$						
ω_0	0.0417*	0.0274*	0.0358*	0.0644**	0.0293	0.0555
α_1	0.0633***	0.0595***	0.0621***	0.0649***	0.0418**	0.0839
β_1	0.9199***	0.9271***	0.9111***	0.9162***	0.9456***	0.8808***
Painel C - Correlações médias condicionais ($\overline{\rho_{ij,t}}$)						
CAC		0.9485***	0.8313***	0.8966***	0.3728***	0.1442***
DAX			0.8186***	0.8494***	0.3491***	0.1535***
FTSE				0.7521***	0.4047***	0.1734***
MIB					0.3483***	0.1357***
Brent						0.3005***
Coeficientes de ajustamento do processo de correlação condicional						
$\alpha = 0.0246***$ (lambda 1)						
$\beta = 0.9407***$ (lambda 2)						

Tabela 42: Estimação do Modelo VAR(1) - DCC-MGARCH(1,1) para os mercados acionistas Asiáticos e o mercado de *commodities* (CSI300, NIKKEI, Brent, Ouro)

	CSI	NIKKEI	Brent	Ouro
Painel A - Equações da média condicional				
Const.	-0.03	0.02	0.03	0.01
CSI300(-1)	-0.05*	-0.02	0.01	7.1E-4
NIKKEI(-1)	-0.5	-0.17***	-0.04	-0.02
Brent(-1)	0.11***	0.19***	-0.003	0.02
Ouro(-1)	0.01	0.003	0.01	-0.4
Painel B - Equações da variância condicional				
$h_{ii,t} = \omega_0 + \alpha_1 \varepsilon_{i,t-1}^2 + \beta_1 h_{ii,t-1}$				
ω_0	0.2350	0.2786	0.0251	0.0516
α_1	0.0418	0.1899	0.0382***	0.0775
β_1	0.8387***	0.6479***	0.9510***	0.8894***
Painel C - Correlações médias condicionais ($\overline{\rho_{ij,t}}$)				
CSI		0.2726***	0.1574***	0.1000***
NIKKEI			0.1071***	0.0346***
Brent				0.2963***
Coeficientes de ajustamento do processo de correlação condicional				
$\alpha = 0.0237***$ (lambda 1)				
$\beta = 0.8722***$ (lambda 2)				

Apêndice (G) - Outputs do modelo DCC-MGARCH no período da crise financeira global 2007-2009

Tabela 43: Estimação do Modelo VAR(1) - DCC-MGARCH(1,1) para os mercados acionistas Europeus e o mercado de *commodities* (CAC40, DAX, FTSE100, MIB, Brent, Ouro)

	CAC	DAX	FTSE	MIB	Brent	Ouro
Painel A - Equações da média condicional						
Const.	-0.06	-0.04	-0.07	-0.07	-0.01	0.08
CAC40(-1)	-1.02***	-0.86***	-0.54***	-0.94***	-0.27	-0.09
DAX(-1)	0.63***	0.46***	0.59***	0.54***	0.45***	0.04
FTSE100(-1)	0.40***	0.33***	0.01	0.40***	0.03	0.03
MIB(-1)	-0.004	0.02	-0.04	0.04	-0.14	0.07
Brent(-1)	-0.07*	-0.05	-0.04	-0.09**	-0.12**	-0.02
Ouro(-1)	-0.01	0.02	0.02	-0.06	0.06	0.06
Painel B - Equações da variância condicional						
$h_{ii,t} = \omega_0 + \alpha_1 \varepsilon_{i,t-1}^2 + \beta_1 h_{ii,t-1}$						
ω_0	0.0817	0.0624	0.0840*	0.0774	0.0813*	0.0295
α_1	0.1217***	0.1145***	0.1052***	0.1327***	0.0773***	0.0476***
β_1	0.8708***	0.8805***	0.8769***	0.8628***	0.9124***	0.9404***
Painel C - Correlações médias condicionais ($\overline{\rho_{ij,t}}$)						
CAC		0.9581***	0.8683***	0.9409***	0.4157***	0.2209***
DAX			0.8280***	0.9242***	0.4154***	0.2410***
FTSE				0.8162***	0.4350***	0.1972***
MIB					0.4213***	0.2251***
Brent						0.4170***
Coeficientes de ajustamento do processo de correlação condicional						
$\alpha = 0.0390$ *** (lambda 1)						
$\beta = 0.893354$ *** (lambda 2)						

Tabela 44: Estimação do Modelo VAR(1) - DCC-MGARCH(1,1) para os mercados acionistas Asiáticos e o mercado de *commodities* (CSI300, NIKKEI, Brent, Ouro)

	CSI	NIKKEI	Brent	Ouro
Painel A - Equações da média condicional				
Const.	-0.01	-0.05	-0.004	0.07
CSI300(-1)	0.02	0.004	-2.5E-4	0.03
NIKKEI(-1)	-0.07*	-0.25***	-0.03	-0.01
Brent(-1)	0.05	0.25***	-0.10**	-0.002
Ouro(-1)	-0.04	-0.06	0.08	0.07
Painel B - Equações da variância condicional				
$h_{ii,t} = \omega_0 + \alpha_1 \varepsilon_{i,t-1}^2 + \beta_1 h_{ii,t-1}$				
ω_0	0.1438	0.0065	0.0726	0.0305
α_1	0.0697**	0.0698***	0.0750***	0.0523***
β_1	0.9068***	0.9230***	0.9159***	0.9356***
Painel C - Correlações médias condicionais ($\overline{\rho_{ij,t}}$)				
CSI		0.2209***	0.1595***	0.0777***
NIKKEI			0.0993***	0.0511***
Brent				0.4139***
Coeficientes de ajustamento do processo de correlação condicional				
$\alpha = 0.0115$ (lambda 1)				
$\beta = 0.8787$ ** (lambda 2)				

Apêndice (H) - Gráficos das correlações condicionais dinâmicas do modelo DCC-MGARCH no período da crise da Covid-19

Figura 8: Correlações DCC-MGARCH no continente americano (S&P500, TSX, WTI, Ouro)

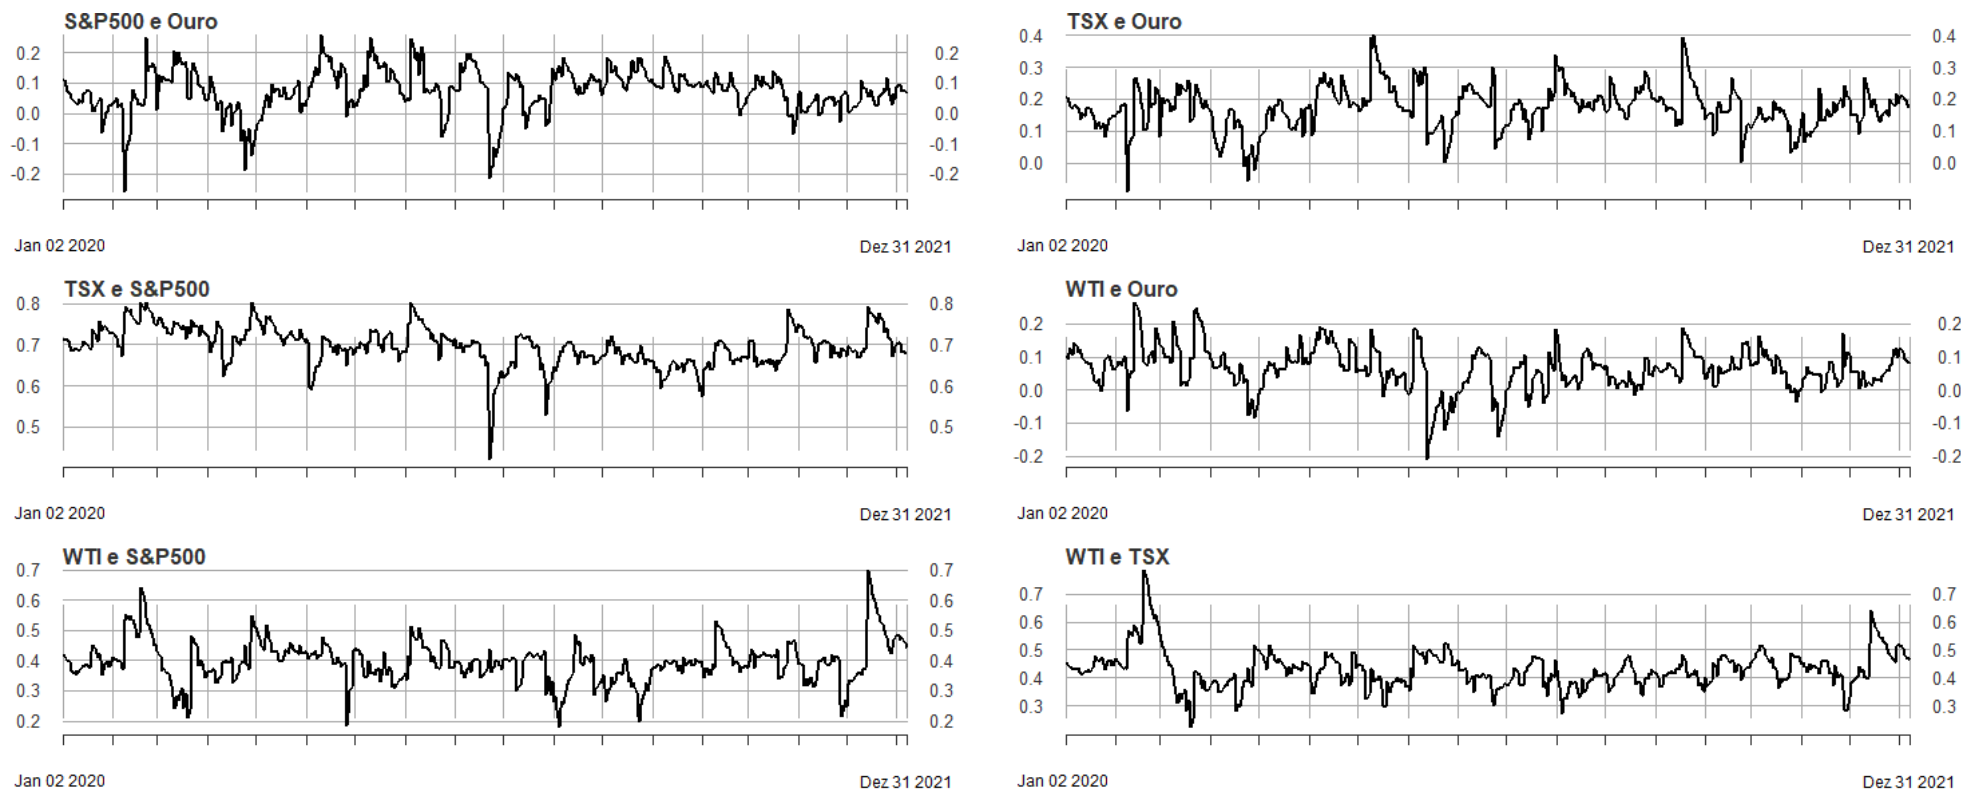


Figura 9: Correlações DCC-MGARCH no continente asiático (CSI300, NIKKEI, Brent, Ouro)












Figura 10: correlações DCC-MGARCH no continente europeu (CAC40, DAX, FTSE100, MIB, Brent, Ouro)





Apêndice (I) - Gráficos das correlações condicionais do modelo DCC-MGARCH no período da crise da Dívida Soberana

Figura 11: Correlações DCC-MGARCH no continente americano (S&P500, TSX, WTI, Ouro)




Figura 12: Correlações DCC-MGARCH no continente asiático (CSI300, NIKKEI, Brent, Ouro)

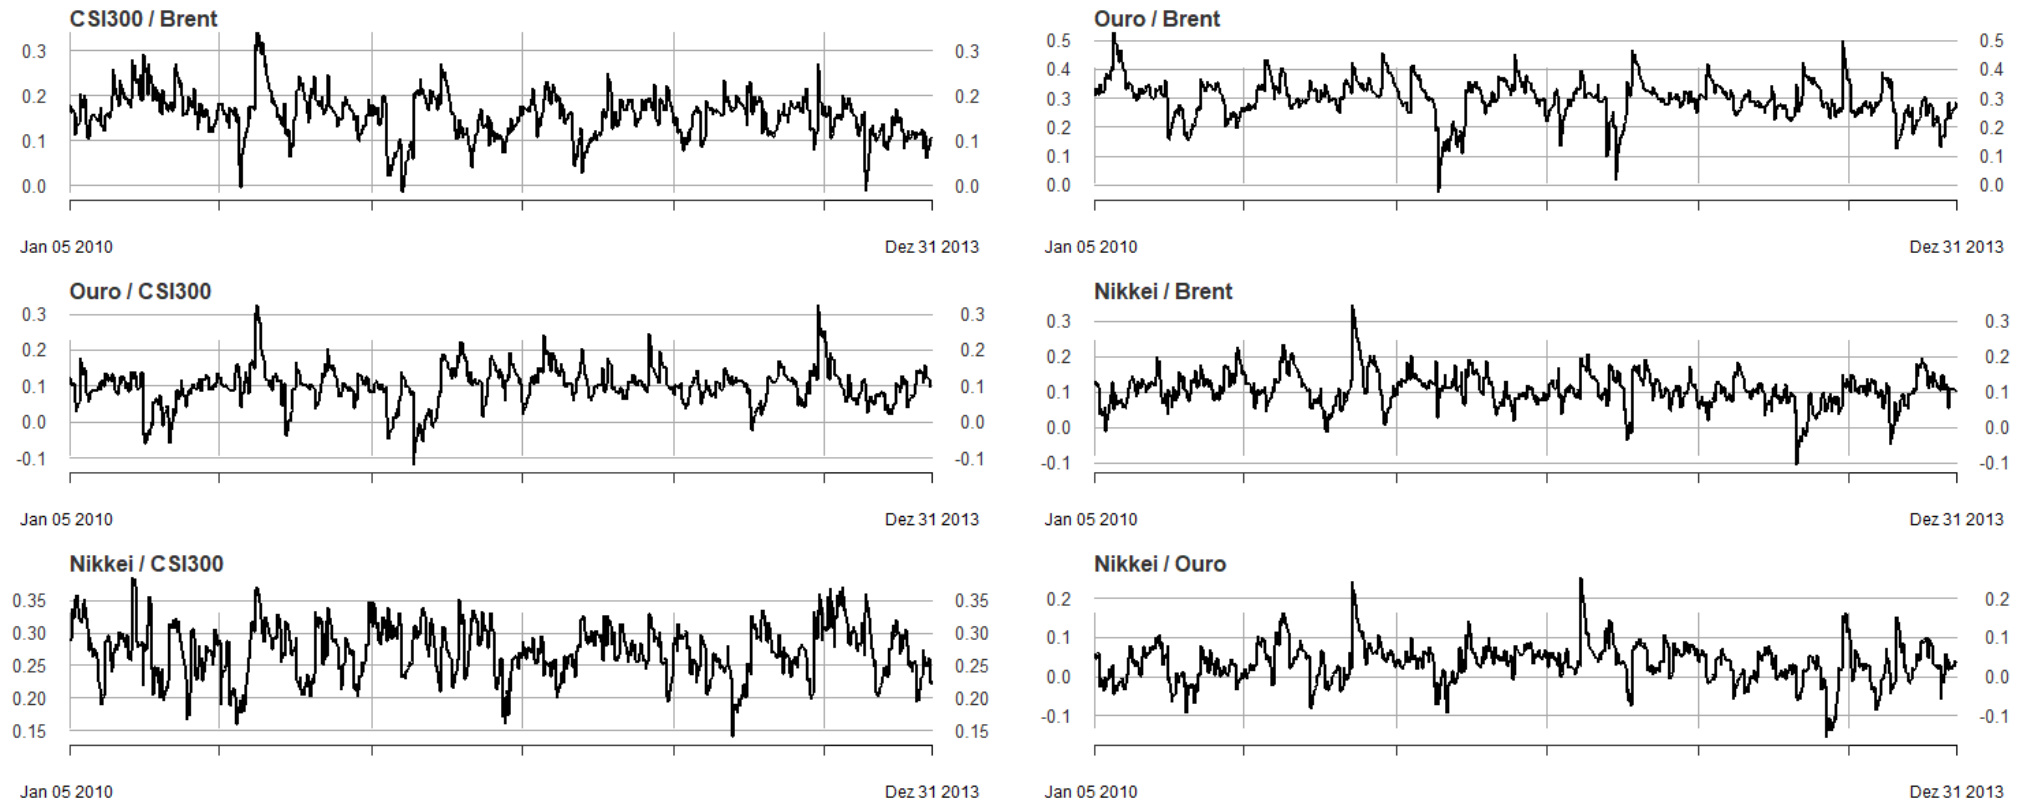










Figura 13: correlações DCC-MGARCH no continente europeu (CAC40, DAX, FTSE100, MIB, Brent, Ouro)





Apêndice (J) - Gráficos das correlações condicionais do modelo DCC-MGARCH no período da crise financeira global 2007-2009

Figura 14: Correlações DCC-MGARCH no continente asiático (CSI300, NIKKEI, Brent, Ouro)




Figura 15: correlações DCC-MGARCH no continente europeu (CAC40, DAX, FTSE100, MIB, Brent, Ouro)

