



Universidade do Estado do Rio de Janeiro
Faculdade de Ciências Econômicas
Programa de Pós Graduação em Ciências Econômicas

Leandro Dias Daumas

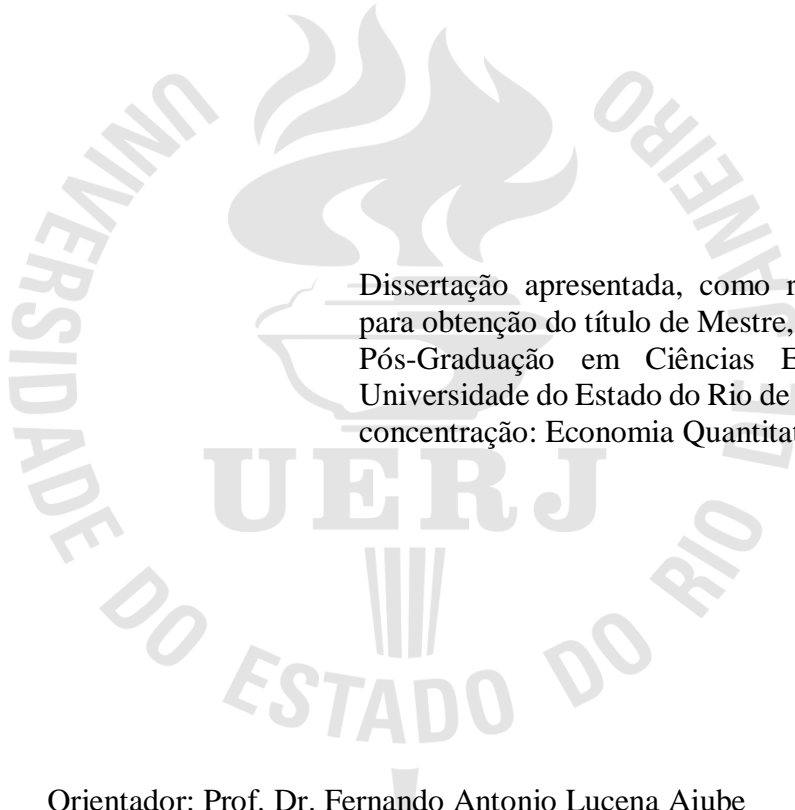
**Análise de *hedge* entre índices de *commodities* e índice de ações através do
*DCC-GARCH***

Rio de Janeiro

2017

Leandro Dias Daumas

Análise de *hedge* entre índices de *commodities* e índice de ações através do *DCC-GARCH*



Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Ciências Econômicas, da Universidade do Estado do Rio de Janeiro. Área de concentração: Economia Quantitativa.

Orientador: Prof. Dr. Fernando Antonio Lucena Aiube

Rio de Janeiro

2017

CATALOGAÇÃO NA FONTE
UERJ / REDE SIRIUS / BIBLIOTECA CCS/B

D241 Daumas, Leandro Dias.

Análise de hedge entre índices de commodities e índice de ações através do DCC-GARCH / Leandro Dias Daumas. – 2017.
54 f.

Orientador: Prof. Dr. Fernando Antonio Lucena Aiube.
Dissertação (mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Ciências Econômicas.
Bibliografia: f.43-46.

1. Economia de mercado – Teses 2. Mercado futuro de mercadorias – Teses. 3. Bolsa de mercadorias – Teses. 4. Modelos econométricos – Teses. I. Aiube, Fernando Antonio Lucena. II. Universidade do Estado do Rio de Janeiro. Faculdade de Ciências Econômicas. III. Título.

CDU 330.133

Autorizo para fins acadêmicos e científicos, a reprodução total ou parcial desta dissertação.

Assinatura

Data

Leandro Dias Daumas

Análise de *hedge* entre índices de *commodities* e índice de ações através do *DCC-GARCH*

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Ciências Econômicas, da Universidade do Estado do Rio de Janeiro. Área de concentração: Economia Quantitativa.

Aprovada em 05 de dezembro de 2017.

Banca Examinadora:

Prof. Dr. Fernando Antonio Lucena Aiube (Orientador)
Faculdade de Ciências Econômicas – UERJ

Prof. Dr. Carlos Alberto Gonçalves da Silva
Faculdade de Ciências Econômicas – UERJ

Prof. Dr. Ariel Levy
Faculdade de Administração e Ciências Contábeis
Universidade Federal Fluminense

Prof. Dr. Tara Keshan Nanda Baidya
Faculdade de Administração
Universidade do Grande Rio

Rio de Janeiro

2017

AGRADECIMENTOS

Primeiramente, gostaria de agradecer ao Programa de Pós-Graduação em Ciências Econômicas da UERJ (PPGCE/UERJ) por me aceitarem como aluno e terem me proporcionado profundo aprendizado que, certamente, foi além da Economia. Sou também muito grato à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo investimento financeiro que me permitiu dar dedicação integral ao curso de mestrado.

No âmbito acadêmico, sou imensamente grato em especial: ao Prof. Fernando Aiube, por ter sido um excelente orientador e professor em todos os aspectos; ao Prof. Carlos Alberto Gonçalves, por ter sido um professor exemplar e ter me auxiliado tanto dentro quanto fora da sala de aula; ao Prof. Ronaldo Serôa pelo exemplo de integridade e engajamento que deu como coordenador do curso e; em especial à Sra. Rosangela Lemos pela sua dedicação incondicional como chefe da secretaria do curso que, mesmo frente à inúmeras dificuldades, manteve-se firme cuidando de todos os alunos como se fossem seus filhos.

Em meu círculo social, registro aqui minha gratidão aos colegas de curso, em especial aos amigos que fiz durante essa jornada no mestrado e levarei para a vida, principalmente aos Srs. Lucas Frazão, Luis Novoa, Salatiel Turra e Winicius Faquiere e as Srtas. Ana Maria Morais, Denise Manfredini, Fernanda Rangel, Julia Dias, Juliana Gagliardi, Karinna Iulio, Lynda Pavão e Ruthiany Costa.

Obviamente, serei eternamente grato à minha família, em especial ao meu pai, Sr. Francisco Carlos Daumas, à minha mãe, Sra. Carmina Dias Daumas, e à minha irmã, Srta. Clara Dias Daumas, por todo amor e carinho que me proporcionaram forças para obter essa conquista e tantas outras que consegui na vida. Por último, agradeço a mim mesmo por nunca ter desistido mesmo ante os obstáculos da vida e por ter me permitido superar meus próprios limites e a Deus pelo dom da vida e por mais essa chance de me tornar uma pessoa melhor.

You're constantly trying to prove yourself, even after you've made it.

Chester Bennington (in memoriam)

RESUMO

DIAS DAUMAS, LDD. **Análise de *hedge* entre índices de *commodities* e índice de ações através do *DCC-GARCH***. 2017. 54 f. Dissertação (Mestrado em Ciências Econômicas) – Faculdade de Ciências Econômicas, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2017.

Esse trabalho tem como objetivo analisar como o Standard & Poor's Goldman Sachs Commodity Index (S&P-GSCI) e seus subíndices foram utilizados como *hedge* (proteção) para o índice Standard & Poor's 500 entre os anos 1999 e 2017, principalmente em momentos de crise no mercado financeiro. Tendo em vista a necessidade de estimar a variação da correlação entre os índices ao longo do tempo foi utilizado o modelo *Dynamic Conditional Correlation-GARCH (DCC)* de Engle e, a partir dos valores estimados, foram realizadas análises gráficas e calculadas métricas relativas à capacidade de um ativo financeiro servir de *hedge* ou até mesmo como *safe haven* (porto seguro) para outro ativo. Constatou-se que as correlações condicionais entre os índices de *commodities* e o S&P500 se elevaram consideravelmente a partir de 2004, considerado marco inicial do fenômeno da financialização de *commodities*, e registraram dois momentos de inflexão em 2008: um de forte queda antes da eclosão da crise dos *subprime* em setembro e outro de substancial ascensão depois. Anos depois, as correlações condicionais voltaram a aumentar, em menor magnitude em relação à crise de 2008, após a queda geral do preço das *commodities* no segundo semestre de 2014. O índice de Metais Preciosos serviu de *hedge* para o índice S&P500 durante a maior parte do período e serviu de *safe haven* na crise de 2008, além de ter registrado o menor custo médio de *hedge* enquanto o índice de Metais Industriais teve o pior desempenho como *hedge* e, na média, apresentou o custo mais elevado.

Palavras-chave: *Commodities*. *DCC-GARCH*. *Hedge*. Correlação condicional.

ABSTRACT

DIAS DAUMAS, LDD. *Hedge analysis between commodities' and stock's indexes through DCC-GARCH*. 2017. 54 f. Dissertação (Mestrado em Ciências Econômicas) – Faculdade de Ciências Econômicas, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2017.

The main goal of this dissertation is to analyze the performance of S&P Goldman Sachs Commodity Index and its subindices as hedge to S&P500 index during the period between 1999 and 2017, especially during the crisis moments of financial market. To estimate conditional correlation between the indexes through time Engle's DCC-GARCH model was applied. From the estimated values, graphic analysis were made and hedge metrics were calculated both related to assess the hedge of a financial asset to another. It was found that conditional correlations between commodity and S&P500 indexes has quite increased from 2004 onwards, when the commodities' financialization phenomenon has begun, and had two moments of inflection in 2008: a strong fall before the subprime crisis outbreak and a substantial ascension after. Years later, conditional correlations had increased again, lesser than in 2008, after commodities' price bust in 2014's second half. The Precious Metals' subindex has served as hedge to S&P500 index during most part of the time, has served as safe haven during 2008's subprime crisis and also has registered the lowest hedge's average cost while the Industrial Metals' subindex had the worst hedging performance and was the most expensive hedging alternative.

Keywords: Commodities. DCC-GARCH. Hedge. Conditional correlation.

LISTA DE FIGURAS

Figura 1 - Evolução dos índices S&P500 versus S&P-GSCI	32
Figura 2 - S&P500 <i>versus</i> S&P-GSCI.....	36
Figura 3 - S&P500 <i>versus</i> Agricultura.....	52
Figura 4 - S&P500 <i>versus</i> Energia	52
Figura 5 - S&P500 <i>versus</i> Metais Preciosos	53
Figura 6 - S&P500 <i>versus</i> Pecuária	53
Figura 7 - S&P500 <i>versus</i> Metais Industriais.....	54

LISTA DE TABELAS

Tabela 1 - Estatísticas Descritivas - Séries de retornos	33
Tabela 2 – Resultados das estimações	35
Tabela 3 - Correlações condicionais - Estatísticas	37
Tabela 4 - Relação temporal de <i>hedge</i>	39
Tabela 5 - Taxa de <i>Hedge</i> de Kroner e Sultan.....	41
Tabela 6 - Peso ótimo de portfólio de Kroner e Ng.....	41
Tabela 7 - Resultados das estatísticas dos testes	50
Tabela 8 - Correlações condicionais (apenas <i>commodities</i>) - Estatísticas	51

SUMÁRIO

INTRODUÇÃO	10
2. REVISÃO BIBLIOGRÁFICA	12
3. METODOLOGIA	26
3.1. Modelo DCC-GARCH.....	26
3.2. Métricas de <i>Hedge</i>	28
3.2.1. Relação temporal de <i>Hedge</i>	29
3.2.2. Taxa de <i>Hedge</i>	29
3.2.3. Peso ótimo de portfólio	30
3.3. Dados Empíricos.....	30
4. ANÁLISE DE RESULTADOS	34
4.1. Estimação do modelo <i>DCC-GARCH</i>	34
4.2. Resultados das métricas de <i>Hedge</i>	39
CONCLUSÕES	42
REFERÊNCIAS	43
APÊNDICE A - Modelos <i>GARCH</i> estimados.....	47
APÊNDICE B - Tabela com testes de consistência dos modelos estimados	50
APÊNDICE C - Correlações condicionais entre <i>commodities</i>	51
APÊNDICE D - Gráficos das correlações condicionais S&P500 versus <i>commodities</i>	52

INTRODUÇÃO

Na década anterior, o aumento generalizado dos preços das *commodities*, insumos de uso difundido com preços cotados internacionalmente, atraiu a atenção do mundo como um todo, em especial dos agentes que participam do mercado financeiro. Denominado popularmente como “*boom das commodities*”, tal fenômeno atraiu a atenção dos participantes do mercado financeiro pelos altos retornos financeiros que poderiam ser obtidos negociando derivativos relacionados a esses bens como, por exemplo, os contratos futuros de *commodities*. Mais precisamente, a literatura define o período no qual perdurou esse evento entre 2004 e 2009, após a crise dos *subprime* em 2008.

Não há um consenso no meio acadêmico quanto aos principais fatores que proporcionaram o “*boom das commodities*”. Entre as supostas causas apontadas, surgiu a hipótese da “*financiarização*” das *commodities*, processo que explicaria a alta generalizada de preços de *commodities* a partir da entrada de agentes de outros segmentos de finanças no mercado futuro desses bens com a finalidade apenas de auferir ganhos financeiros, ou seja, sem interesse algum em comprar ou vender *commodities*. Na literatura acadêmica alguns autores defendem a mudança de comportamento dos negociadores de contratos futuros de *commodities* como principal influência na trajetória crescente de preços na última década, ao passo que outros refutam essa hipótese expondo outros elementos responsáveis pelo “*boom das commodities*”, como, por exemplo, o forte aumento da demanda por *commodities* de países como China e Índia no período, sobretudo por parte dos chineses.

De fato, a estrutura e o modo de funcionamento do mercado futuro de *commodities* permitem que um investidor participe das transações tomando posições de compra ou venda nesses contratos sem necessariamente ter interesse na obtenção do ativo físico. Na situação de aumento generalizado de preços futuros de *commodities*, os retornos financeiros no mercado futuro se tornaram cada vez mais atrativos não só para os agentes interessados em comprar e vender *commodities*, mas também para especuladores e agentes buscando *hedge* (proteção) contra perdas em outros ativos financeiros como ações e títulos públicos. O desenvolvimento dessa modalidade de negociações e o crescimento da liquidez desses mercados tornou o investimento financeiro em *commodities* uma alternativa de diversificação de risco para os investidores. O sucesso de instrumentos como índices de *commodities* e os Exchange Traded Funds (ETF) facilitaram ainda mais a entrada de novos agentes nesse ambiente de negócios.

Independente da causa desse “boom”, eventos recessivos como a crise dos *subprime* e, posteriormente, a crise da dívida soberana europeia, tiveram impacto em todo o sistema financeiro gerando um ambiente de muita incerteza e receio, alterando o comportamento de seus participantes. Uma das consequências da crise da dívida soberana europeia, por exemplo, foi a queda generalizada dos preços das *commodities* a partir do segundo semestre de 2014. Novamente, a especulação e a recessão econômica surgiram como fatores determinantes para tal evento.

Mais ainda, acredita-se que em meio a esses choques e mudanças no cenário econômico mundial, a possibilidade de se proteger de perdas do mercado financeiro, principalmente no mercado acionário, utilizando derivativos de *commodities* se reduziram consideravelmente. Contudo, dado que as *commodities* não se tratam de bens homogêneos - pois o principal fator em comum entre si é a demanda de diversos setores da economia para uso dessas como insumo - provavelmente nem todas se comportaram financeiramente da mesma maneira. Exemplificando, o ouro sempre foi visto historicamente no mercado financeiro como um investimento seguro enquanto o cobre sempre funcionou como um previsor dos ciclos de negócios.

Portanto, o objetivo do presente trabalho se trata de verificar, dentre as *commodities*, qual desempenhou um comportamento nos retornos dos preços ao longo das últimas duas décadas que serviu de *hedge* para as ações e, se em momentos de crise no mercado financeiro (*subprime* e união europeia) e de queda nos preços de *commodities*, alguma *commodity* serviu como um *safe haven* (porto seguro) para o mercado acionário. Adicionalmente, pretende-se verificar o comportamento dos investidores (preço e correlação) nesses momentos tendo em vista o debate vigente sobre o processo de financialização das *commodities*. Tal avaliação se faz relevante devido aos recentes eventos de ordem financeira e política que desestabilizaram a ordem econômica no mundo, multiplicando as fontes de incerteza entre os agentes participantes da economia mundial. O Capítulo 2 mostra a Revisão Bibliográfica relacionada ao tema, o Capítulo 3 apresenta em detalhes a Metodologia e os Dados Empíricos selecionados para esse trabalho, o Capítulo 4 exhibe a Análise de Resultados obtidos e o Capítulo 5 encerra com as Conclusões.

2. REVISÃO BIBLIOGRÁFICA

A importância das *commodities* na economia mundial vai além do fato de se tratarem, em geral, de insumos para indústrias de diversas atividades econômicas. Por exemplo, Levine, Ooi e Richardson (2016) constataram a partir de uma análise de dados datados entre 1877 e 2015 que os preços futuros de *commodities* serviram de *hedge* (proteção) contra a variações da inflação e apresentaram baixa correlação com títulos públicos e ações ao longo do tempo, ou seja, costumam funcionar como *hedge* para esses ativos. Há dez anos, Erb e Harvey (2006) já haviam notado que um portfólio contendo *commodities* e ações oferece maior retorno esperado e menor risco do que carteiras que contenham somente ações, o que torna os derivativos e os índices atrelados a esses bens instrumentos indispensáveis para diversificação de portfólios. Em outras palavras, as *commodities* são ainda mais relevantes como ativos financeiros.

Baur e Lucey (2010) definiram o conceito de *hedge* como um ativo não-correlacionado ou negativamente correlacionado com outro na média, o que *a priori* não garante que, em tempos de crise no mercado financeiro, o sinal da correlação passe a ser positivo. Há um outro conceito semelhante denominado *safe haven* (“porto seguro”) que ocorre quando um ativo tem correlação não-positiva com o outro em momentos de crise, não importando se na média ou na maior parte do tempo a correlação é positiva.

Os principais fatos estilizados das séries financeiras de retornos de preços são: “estacionariedade; fraca dependência linear e forte dependência não linear; caudas pesadas da distribuição ou excesso de curtose e; comportamento heterocedástico condicional” (AIUBE, 2013). Essas características são comumente encontradas da mesma forma nas séries de retornos de preços futuros de *commodities*, o que viabiliza a aplicação do modelo Generalizado Autorregressivo Condicionalmente Heterocedástico ou simplesmente modelo *GARCH* elaborado por Bollerslev (1986), capaz de estimar e prever a evolução da volatilidade (variância) condicionais destes, sendo esta última a principal medida de risco utilizada no mercado financeiro e principal objeto de estudo de vários trabalhos acadêmicos.

Posteriormente, surgiram os modelos *GARCH* multivariados¹, capazes de expandir o campo de estudo em finanças permitindo analisar a relação entre o comportamento entre os ativos e, mais especificamente, trabalhar com métricas variantes no tempo como a taxa ótima de *hedge* de Kroner e Sultan (1993) e o peso ótimo de portfólio de Kroner e Ng (1998). Os

¹Ver Bauwens, Laurent e Rombouts (2006) e Silvennoinen e Teräsvirta (2009) para maiores informações sobre modelos *GARCH* multivariados.

modelos *Vector Error Correction GARCH (VEC-GARCH)* de Bollerslev, Engle e Wooldridge (1988) e *Baba-Engle-Kraft-Kroner GARCH (BEKK-GARCH)* de Engle e Kroner (1995), sendo o segundo uma versão específica do primeiro, foram elaborados para estimar a covariância condicional entre ativos.

A modelagem possui o mesmo embasamento dos modelos de Vetores Autorregressivos (VAR) e VEC: toda variância e covariância condicional é função de todas as variâncias e covariâncias condicionais defasadas, bem como dos retornos quadrados defasados e dos produtos cruzados dos retornos. Apesar de ser um modelo geral e flexível, somente em condições restritas a matriz de covariância é positiva definida para todo t , condição necessária para a convergência do modelo. O modelo *BEKK-GARCH*, por sua vez, apresenta matrizes positivas definidas na sua própria construção. Por outro lado, sua estimação pode apresentar dificuldades de convergência dado que o modelo não é linear nos parâmetros. Alguns anos depois, Kawakatsu (2006) sugeriu uma generalização do modelo *Exponential GARCH (EGARCH)* de Nelson (1991) para estimar a covariância condicional, no qual se garante a positividade da matriz de covariância e se torna possível captar o efeito alavancagem, sendo que a única ressalva do modelo diz respeito à grande quantidade de parâmetros a serem estimados.

Outra classe de modelos multivariados de covariância condicional derivou dos modelos de fatores ARCH ou *factor ARCH* univariados de Engle, Ng e Rothschild (1990), cuja estrutura parte do conceito de que as observações são geradas por fatores subjacentes condicionalmente heterocedásticos que possuem uma estrutura do tipo *GARCH*, selecionados através da Análise de Componentes Principais (ACP), método estatístico capaz de identificar os fatores que mais influenciam na volatilidade dos ativos selecionados para modelagem. O modelo de fatores apresenta uma inconveniência dado que esses fatores subjacentes poderem ser correlacionados entre si, levando a outros autores buscarem alternativas, como o modelo Ortogonal Generalizado *GARCH* ou simplesmente *GO-GARCH* de Weide (2002), uma expansão do modelo *GARCH* Ortogonal de Alexander e Chibumba (1997). Nesse caso, os fatores não são correlacionados mas existe a limitação de o número de fatores não poder ser menor do que o número de ativos. Anos depois, Lanne e Saikkonen (2007) propuseram uma combinação dos modelos anteriores criando o *Generalized Orthogonal Factor GARCH model* ou modelo *GOF-GARCH*. Além da ausência de correlação entre os fatores, alguns desses podem ser condicionalmente homocedásticos, permitindo que o modelo inclua componentes não apenas de risco sistemático mas também de risco idiossincrático.

Uma determinada classe de modelos *GARCH* multivariados foi além das anteriores, possibilitando a decomposição da matriz de covariância condicional em desvios-padrão e correlações condicionais. O primeiro dessa família foi o *Constant Conditional Correlation GARCH* ou *CCC-GARCH* de Bollerslev (1990), cuja matriz de correlação não varia com o tempo. Essa modelagem se desenvolve a partir da estimação de modelos *GARCH*. A principal limitação do modelo reside no fato de as correlações condicionais serem constantes ao longo do tempo, o que não condiz com a prática, e para essa restrição deixar de existir Tse e Tsui (2002) decidiram tornar a matriz variante ao longo do tempo estimando as correlações condicionais em função das correlações condicionais do período anterior e de um conjunto de correlações estimadas, dando origem ao modelo *Varying Correlation GARCH* ou *VC-GARCH*, que a seu turno tinha certas restrições para manter a matriz de correlação condicional positivamente definida durante todo o período.

Com estrutura similar, Engle (2002) criou o modelo *DCC-GARCH* onde “DCC” significa Correlação Condicional Dinâmica ou *Dynamic Conditional Correlation*. Nesse caso, a modelagem utiliza um método que garante que a matriz de correlação seja sempre positiva definida. Contudo, assim como o modelo *VC-GARCH* a estrutura dinâmica das correlações condicionais é a mesma para todas as séries. Billio, Caporin e Gobbo (2006) propuseram o modelo *DCC-GARCH* Flexível ou *FDCC-GARCH* com o intuito de eliminar essa rigidez, porém os autores asseveraram que esse método depende de certas condições pré-determinadas e a quantidade elevada de parâmetros dificulta a estimação. Cappiello, Engle e Sheppard (2006) decidiram introduzir a assimetria criando o modelo *AGDCC-GARCH* ou *Asymmetric Generalized DCC-GARCH*, permitindo a estimação do efeito alavancagem nas correlações condicionais. Bem como o FDCC, o número grande de parâmetros pode inviabilizar a convergência do modelo.

Fora esses, outros modelos *GARCH* multivariados foram elaborados tais como o *Smooth Transition² Conditional Correlation GARCH* (*STCC-GARCH*) de Silvennoinen e Teräsvirta (2005) e suas diversas variações, além de aproximações não-paramétricas e semiparamétricas desenvolvidas posteriormente. Apesar de não se tratarem de modelos *GARCH* “puros” seja por envolverem variáveis exógenas ou basicamente por não serem totalmente paramétricos, esse último grupo de modelo é visto como uma boa maneira de aprimorar as análises empíricas nas quais se costumam aplicar a modelagem *GARCH*³. Mesmo assim, para os propósitos desse trabalho o *DCC-GARCH* foi escolhido por ser o mais simples e eficiente para se obter as

² “Transição Suave” em português.

³ Para maiores detalhes ver Silvennoinen e Teräsvirta (2009).

correlações condicionais. O *DCC-GARCH* permite que se verifique a evolução da correlação condicional ao longo do tempo entre duas séries distintas, propriedade muito útil para as pesquisas que estudam a interação entre retornos de preços de ativos diferentes para detectar a possibilidade ou não de um ativo servir de *hedge* para o outro e vice-versa. Por exemplo, se o preço futuro do petróleo varia no sentido inverso ao preço de um índice de ações, denotando correlação negativa, torna-se interessante para o investidor em ações, a título de diversificação de risco, aplicar parte de seus recursos no mercado futuro de petróleo. A propósito, trabalhos como o de Sadorsky (1999) e de Arouri (2011) já haviam encontrado uma relação entre os movimentos de preços de petróleo e de ações fazendo uso de outros modelos, reforçando a importância do estudo da correlação condicional entre esses ativos.

Na década atual, diversos autores utilizaram o modelo *DCC-GARCH* envolvendo commodities, ações e outros ativos, bem como comparando o desempenho deste com outras modelagens similares, Chong e Miffre (2010) avaliaram através da modelagem *DCC-GARCH* o nível de correlação ao longo do tempo entre séries de retornos de preços futuros de 25 *commodities* (agrícolas, energéticas, pecuária e metais preciosos) e os retornos de preços de 13 ativos financeiros tradicionais como títulos públicos (*bonds*) e ações (*stocks*), correspondentes aos seguintes mercados: EUA; Europa; Ásia; América Latina e; África. Os dados se referem ao período entre Janeiro de 1981 até Dezembro de 2006. Em seguida, os autores aproveitaram os valores estimados do modelo e rodaram uma regressão linear usando as correlações condicionais como variáveis endógenas e as volatilidades condicionais como variáveis exógenas. Dentre as conclusões, pode-se destacar que as correlações condicionais entre retornos de preços *commodities* e retornos do índice S&P500, principal índice do mercado de ações norte-americano, decresceram ao longo do tempo, o que significa que as *commodities* se tornaram melhor instrumento de *hedge* para ações e vice-versa. Na maioria dos casos, foi também constatada queda de correlação condicional entre *commodities* e índices de ações de outras regiões do mundo. Ademais, nota-se claramente que não se pode ignorar a heterogeneidade das *commodities* como ativos financeiros, dada a diversidade dessas, e registrou-se uma relação inversa entre a correlação condicional e a volatilidade, favorecendo a diversificação de risco em períodos turbulentos no mercado. Tal fenômeno ocorreu com metais preciosos mas não com *commodities* de energia. No mais, em termos de correlações condicionais com o S&P500, 11 das 25 *commodities* apresentaram correlação negativa com a volatilidade do índice S&P500 enquanto que, em relação aos títulos públicos, a redução de risco através de *hedge* usando *commodities* pode ser considerada uma alternativa viável somente para títulos de curto prazo. Vale destacar que, quanto à periodicidade dos dados, quando os autores

passaram da base semanal para a base diária de dados, notaram algumas divergências nos resultados obtidos na estimação dos referentes modelos, atestando melhor estimação com a base de maior frequência.

Choi e Hammoudeh (2010) aplicaram os modelos *Markov-switching GARCH* e *DCC-GARCH* nos dados semanais dos retornos dos preços de fechamento de cinco *commodities* estratégicas - ouro, petróleo (WTI e Brent), prata e cobre - e do índice S&P500. Os dados coletados correspondem ao período entre Janeiro de 1990 e Maio de 2006. O primeiro modelo teve como propósito medir as mudanças entre regimes de alta e baixa volatilidade (e a duração destes) ao passo que o segundo serviu para avaliar o comportamento da correlação entre as séries de *commodities* e o índice de ações, tanto no período amostral como um todo quanto nos seguintes quatro subperíodos: 1990-1997 (pré-crise da Ásia); 1997-2006 (pós-crise da Ásia); 1990-2001 (pré-ataques terroristas nos EUA) e; 2001-2006 (pós-ataques terroristas nos EUA). Os resultados relativos ao *DCC-GARCH* apontaram para um decréscimo generalizado da correlação condicional entre *commodities* e o índice S&P500 no final do período em análise. Adicionalmente, os índices de petróleo apresentam maior persistência na volatilidade em resposta a crises geopolíticas, enquanto o cobre se mostrou mais sensível a crises financeiras e o índice S&P500 demonstrou maior sensibilidade em ambos os casos.

Em linha com os trabalhos acima mencionados, Creti, Joëts e Mignon (2013) investigaram como retornos diários de preços - de *commodities* diversas e do S&P500 - se relacionaram ao longo do período entre Janeiro de 2001 e Novembro de 2011, com ênfase em matérias-primas usadas para gerar energia (“energéticas”), selecionando séries diárias de 25 *commodities* diversas dos setores de energia, metais preciosos, agricultura, metais não-ferrosos, alimentos, oleaginosas, exóticas (cacau, café e açúcar) e pecuária. Além destas, os autores coletaram séries dos índices S&P500 e CRB (*commodities*). A metodologia foi aplicada para quatro sub-amostras - bem como para a amostra principal - de Janeiro de 2001 até Março de 2003; de Março de 2003 até Outubro de 2007; de Outubro de 2007 até Março de 2009 e; de Março de 2009 até Outubro de 2011 - com a finalidade de captar efeitos de eventos específicos geopolíticos e crises financeiras. Segundo os autores, a matriz de variância-covariância do *DCC-GARCH* nem sempre é consistente e, para contornar possíveis entraves na metodologia do trabalho, os autores optaram por fazer uso do modelo “*cDCC GARCH*” proposto por Aielli (2013), eliminando o risco de inconsistência da matriz de variância-covariância. Entre as principais conclusões, Creti, Joëts e Mignon (2013) constataram que as correlações denotaram alta volatilidade durante o período inteiro, principalmente naquele que inclui a crise dos *subprime* de 2008. Não por acaso, as maiores quedas das correlações se deram justamente nessa

crise, fenômeno que ocorreu no curtíssimo prazo. Por outro lado, logo em seguida, a correlação aumentou alcançando os mais elevados níveis (de magnitude superior às registradas antes da crise). Ademais, constatou-se um movimento especulativo no petróleo, no cacau e no café: os retornos destes cresceram junto com o aumento dos retornos do S&P500 e diminuíram quando o mercado financeiro apresentou tendência de queda ou o chamado *bear market*, momento no mercado quando os investidores, na expectativa de declínio dos preços dos ativos, decidem vender os ativos que possuem. Vale notar que o ouro registrou números satisfatórios suficientes para servir como *safe haven* para o mercado de ações (correlação negativa quando o preço das ações caem) e a mudança do comportamento da correlação entre ações e *commodities* após 2008 mostrou que, entre as séries analisadas somente o ouro, o café e o cacau teoricamente poderiam servir de *hedge* num portfólio com ações.

Utilizando os mesmos métodos das pesquisas anteriores embora com uma proposta de outra natureza, Manera, Nicolini e Vignati (2013) elaboraram um modelo econométrico cuja variável dependente são os retornos de preços futuros de *commodities* e as variáveis exógenas são: a taxa de juros, a taxa de câmbio, o índice S&P500 e o índice *Working's T*, indicador usado para mensurar o excesso de especulação existente no mercado futuro. A essa regressão linear aplicaram o *DCC-GARCH* para avaliar o *spillover* (contágio) impacto de retornos de preços defasados de uma série nos retornos de preços correntes de outra - entre os mercados bem como a evolução da correlação entre as variáveis acima e as *commodities* em análise. As *commodities* selecionadas são oriundas dos setores de energia (gasolina, óleo combustível, gás natural e petróleo bruto) e de agricultura (óleo de soja, milho, aveia, soja em grão e trigo). O trabalho utilizou séries de dados, referentes aos ativos supracitados, em base semanal datados no período entre a terceira semana do ano de 1986 e a última semana do ano de 2010. Os resultados confirmaram uma correlação positiva e significativa entre os retornos de preços de *commodities* e o índice S&P500 e uma correlação negativa e significativa entre os retornos de preços de *commodities* e a taxa de câmbio. Em contraste com as variáveis independentes supracitadas, o índice *Working's T* mostrou-se não significativo em geral, revelando uma influência irrelevante da especulação nos retornos durante o período em análise. Ainda sobre especulação, os autores constataram que a especulação de um mercado não afetou de forma significativa os retornos de preços de outros mercados. Em relação aos *spillovers*, observou-se que as primeiras defasagens de petróleo bruto e gás natural afetaram positivamente retornos correntes de outras *commodities* de energia. Além disso, tanto a correlação entre óleo de soja e outras *commodities* de energia quanto a correlação entre *commodities* agrícolas para fins agro e *commodities* agrícolas para fins energéticos apresentaram valores maiores durante a crise do *subprime*. Por fim, os valores

das correlações condicionais, em média, aumentaram após 2004 e, no caso dos mercados de combustíveis, esses valores chegaram a dobrar.

Büyüksahin e Robe (2014) usufruíram de métodos similares para obter evidências empíricas da financialização nos retornos de preços de *commodities* entre Janeiro de 1991 - quando o GSCI entrou no mercado financeiro - e Março de 2010. Os autores escolheram dados diários e semanais de retornos totais dos índices de *commodities* GSCI, Dow Jones-UBS e Dow Jones-AIG. Para fins comparativos, selecionaram os índices de ações S&P500, Dow Jones' *Industrial Average* e *MSCI World*. De maneira similar a Manera, Nicolini e Vignati (2013), os autores aplicaram o modelo *DCC-GARCH* nas séries supracitadas e calcularam o índice *Working's T* com base nas posições diárias de agentes nos mercados futuros dos EUA referentes a 17 *commodities* e no mercado futuro de mini contratos do índice S&P500. Os autores identificaram dois padrões em relação ao impacto do estresse do mercado financeiro sobre a correlação entre ações e *commodities*. O primeiro diz respeito a relação positiva entre o nível de correlação de ações com *commodities* e o nível de estresse financeiro, indicando que os fundos de *hedge* poderiam ter sido um canal de transmissão de choques negativos do mercado de ações para o mercado de *commodities*, dado que não constataram influência significativa dos demais agentes que atuam em ambos os mercados. Isso justificaria o fato de o poder preditivo das posições de fundos de *hedge* nos mercados futuros de *commodities* ter sido inferior em momentos de estresse. O segundo se refere ao aumento da correlação entre ações e *commodities* após a falência do Lehman Brothers em 2008 devido à crise do *subprime* que se manteve até o final do período em análise. Por fim, diferente do resultado obtido por Manera, Nicolini e Vignati (2013), o índice *Working's T* se mostrou significativo reforçando a ideia de que as flutuações detectadas no mercado de *commodities* e na correlação deste com o mercado de ações se deram por conta da financialização.

Buscando verificar os possíveis *spillovers* entre os mercados de ações e o de *commodities*, Mensi *et al.* (2013) usaram os modelos *VAR-GARCH* e *CCC-GARCH* para avaliar transmissão de choques e de volatilidade entre o índice S&P500 e cinco *commodities* (petróleo WTI, petróleo Brent, ouro, trigo e bebidas⁴) e analisar a otimização de carteira em termos de peso e *hedge* para portfólios contendo os índices supracitados. Os dados foram colhidos em base diária entre Janeiro de 2000 e Dezembro de 2011.

Em relação às médias condicionais, os autores notaram que os retornos correntes dos preços do ouro, do petróleo WTI e do trigo são mais reativos aos retornos do S&P500 com uma

⁴Inclui café, chá e cacau.

defasagem. Somente os retornos do petróleo WTI e do ouro com uma defasagem foram estatisticamente significativos para explicar os retornos correntes do S&P500. A volatilidade passada apresentou, nesse trabalho, maior poder de predição do que os choques passados das séries. A volatilidade passada do S&P500 afetou a volatilidade de todas as *commodities* exceto o trigo enquanto que os choques passados do S&P500 afetaram a volatilidade do ouro, do trigo e das bebidas. Por outro lado, os choques passados do WTI e do Brent tiveram impacto na volatilidade do S&P500 enquanto a volatilidade passada de todas as *commodities*, com exceção do petróleo Brent, influenciaram na volatilidade do S&P500. Em termos de *hedge* o trigo foi a *commodity* de menor custo para servir como *hedge* num portfólio contendo S&P500 enquanto o petróleo Brent foi o mais oneroso.

Öztek e Öcal (2013) modelaram as correlações variantes ao longo do tempo de índices de *commodities* agrícolas, metais preciosos e do índice S&P500 com o propósito de descobrir se a tendência ascendente de preços nesses mercados é consequência da financialização de *commodities* e/ou de crises financeiras, em linha com o propósito do trabalho de Manera, Nicolini e Vignati (2013), investigando o papel das notícias do mercado e da volatilidade a níveis global e de mercado no comportamento histórico da correlação. Os autores utilizaram os modelos (*STCC-GARCH*) e *Double Smooth Transition Conditional Correlation GARCH (DSTCC-GARCH)* nas séries de retornos semanais dos índices S&P-GSCI Agriculture (S&P-AG), S&P-GSCI Precious Metals (S&P-PM), S&P500 e do *Volatility Index (VIX)* -índice que mede as expectativas de mercado quanto à volatilidade dos preços das opções do índice S&P500 - referentes ao intervalo de tempo entre Janeiro de 1990 e Dezembro de 2012. Tais modelos incluem o uso de variáveis de transição como o tempo, o *VIX* e outras como: “variância condicional defasada, erro absoluto defasado e erro absoluto padronizado defasado, erro quadrático defasado, erro quadrático padronizado defasado, erro defasado e; erro padronizado defasado” (ÖZTEK; ÖCAL, 2013).

Em relação aos pares (S&P-AG, S&P500) e (S&P-AG, S&P-PM), os resultados obtidos não corroboraram com a hipótese de tendência ascendente das correlações. Aparentemente, o aumento da correlação entre esses índices se deu por conta de crises financeiras acompanhadas de períodos de alta volatilidade relativa nesses mercados. Portanto, S&P-AG serviu de *hedge* para os demais índices em tempos de calma no mercado financeiro, embora tal possibilidade tenha sido, logicamente, em parte minada durante crises financeiras. Quanto à correlação condicional entre S&P500 e S&P-PM, ainda que haja uma tendência crescente, os níveis de correlação foram fortemente afetados pelas volatilidades de ambos os mercados durante crises

financeiras. Ainda assim, a correlação mais alta detectada entre esses dois ativos foi muito baixa em termos absolutos quando comparadas com o outro par.

Boyrie e Pavlova (2016) avaliaram os possíveis *spillovers* entre ações e *commodities*, nesse caso analisando separadamente índices de mercados acionários de países desenvolvidos e de países em desenvolvimento ao longo dos últimos dez anos. Para tal análise, os autores utilizaram séries de retornos, em base diária, dos seguintes índices: MSCI-World, MSCI-EM (*Emerging Markets*), MSCI-EM *Asia*, MSCI-EM *Europe*, MSCI-EM *LatAm*, GSCI *Commodities*, GSCI *Agriculture*, GSCI *Energy* e GSCI *Precious Metals*. Os dados escolhidos datam do período entre Janeiro de 2006 até Janeiro de 2016 e têm como moeda de referência o dólar. A metodologia da pesquisa consistiu em fazer uso modelo *DCC-GARCH* nos dados com o intuito de utilizar os valores de correlação condicional obtidos para rodar uma regressão múltipla, em base mensal, usando: a correlação defasada; o *Net Investment Index (NII)* -índice criado para medir a participação de investidores de índice no mercado de *commodities* - e; o *VIX*. A regressão teve como objetivo mensurar e avaliar o impacto da financialização das *commodities* e as mudanças nas condições do mercado de ações em função da relação entre os retornos dos preços de *commodities* e retornos dos preços de ações. Primeiramente, os resultados mostraram que a capacidade de *hedge* das *commodities* se restringiu a alguns mercados de ações. A princípio, o modelo *DCC* apresentou de um modo geral fortes oscilações das correlações condicionais ao longo do tempo, principalmente na crise de 2008 quando aumentaram (somente em alguns casos passaram a ser negativas) e tenderam a permanecer elevadas até 2014, exceto na crise econômica de 2011. O aumento de correlação foi comum entre índices de ações e *commodities*, tanto para as agrícolas como para os metais preciosos, mas ocorreu em proporções bem menores do que com as *commodities* de energia. Sob a ótica dos países, as correlações com o índice de ações do continente asiático tenderam a ser inferiores às correlações do índices referentes à Europa e à América Latina. Em relação a regressão, aumentos no investimento em índices de *commodities* corresponderam a quedas das correlações entre ações e *commodities* agro enquanto que aumentos do *VIX* corresponderam a maiores correlações entre ações e *commodities*, na maioria dos casos. No geral, os autores concluíram que *commodities* de energia funcionaram como *hedge* somente para ações de empresas em países desenvolvidos à medida que, para ações de empresas em países em desenvolvimento os metais preciosos foram a melhor escolha.

Corroborando com este último resultado supracitado, Bouri, Boyrie e Pavlova (2017) desenvolveram uma análise de *spillovers* entre *commodities* e *Credit Default Swaps (CDS)* de países em desenvolvimento e países de fronteira (países considerados mais desenvolvidos

dentre os países em desenvolvimento), utilizando o modelo assimétrico *GJR-GARCH* de Glosten, Jagannathan e Runkle (1993) e um teste de hipótese de causalidade entre variância tendo como base retornos diários dos preços, datados entre Junho de 2010 e Julho de 2016, dos *CDS* dos países sob análise e do índice de *commodities* CRB Thompson-Reuters, bem como seus subíndices. Como resultado os autores comprovaram a influência da volatilidade dos índices de *commodities* sobre os *CDS* dos países analisados, sendo os principais subíndices transmissores de volatilidade os de energia e de metais preciosos.

Com ênfase nos países em desenvolvimento, Sadorsky (2014) já havia avaliado a evolução da correlação condicional ao longo do tempo entre o mercado de ações e *commodities* como o petróleo, o cobre e o trigo, verificando qual apresentou a melhor combinação de *hedge* para um portfólio com tais ativos. O autor selecionou as séries de retornos diários de preços dos índices MSCI-EM, WTI (petróleo), COMEX (cobre) e IGC (trigo), aplicando sobre estas os modelos assimétricos *CCC-AGARCH*, *Vector Autorregressive Moving Average Assymetric GARCH (VARMA-AGARCH)* de McAleer, Hoti e Chan (2009) e *DCC-AGARCH* num período entre Janeiro de 2000 e Junho de 2012. O autor escolheu o modelo com melhor ajuste às séries para calcular as taxas de *hedge* (*hedge ratios*) e os pesos ótimos de portfólio (*optimal portfolio weights*). O modelo *DCC-AGARCH* foi considerado o melhor para realizar estimações, previsões e para calcular as taxas de *hedge* e os pesos ótimos de portfólio. A correlação condicional entre o índice de ações dos países em desenvolvimento e as *commodities* selecionadas cresceu fortemente entre 2008 e 2009 e não retornou para os valores pré-crise nos anos seguintes. Constatou-se que, na média, petróleo é o instrumento mais barato de *hedge* para se proteger dos riscos de ações dos países em desenvolvimento. Em termos de portfólio, o trigo é o ativo que apresentou maior peso na carteira para garantir *hedge*. Além disso, o trigo registrou efeito alavancagem negativo, denotando que choques negativos tendem a diminuir a volatilidade em vez de aumentá-la. No geral, as correlações condicionais cresceram após a crise dos *subprime*, atingindo novos patamares históricos.

Identicamente, Demiralay e Ulusoy (2014) optaram pela utilização de modelos multivariados assimétricos, no caso um *ADCC-GARCH* elaborado a partir de modelos *EGARCH* univariados. Além desses, os autores elaboraram dois modelos de regressão linear múltipla (MRLM) cuja correlação condicional foi a variável dependente, sendo que no primeiro estimaram as volatilidades condicionais como variáveis explicativas enquanto no segundo as variáveis independentes foram variáveis dummy referentes às crises: da Ásia e da Rússia (de meados de Novembro de 1997 até final de Outubro de 1998), da bolha da tecnologia (do início de Janeiro até o final de Setembro de 2002) e dos *subprime* (do início de Agosto de 2007

atémeados de Fevereiro de 2009). Foram selecionadas para modelagem as séries de retornos semanais do índice de *commodities* Dow Jones-UBS, dos sub-índices deste (referentes aos setores agrícola, metais preciosos, indústria, gado e energia) e do índice S&P500, referentes ao período entre a primeira semana de Janeiro de 1992 e a última semana de Dezembro de 2013. Dentre as conclusões vale destacar que, com exceção da *commodity* gado, as correlações condicionais entre *commodities* e o S&P500 despencaram durante a crise dos *subprime* e dispararam logo em seguida. Contudo, no final do período em análise, as correlações condicionais praticamente retornaram aos níveis pré-crise. Os autores atribuíram tal movimento à financialização de *commodities* e ao efeito manada. Ainda em relação ao *ADCC-GARCH*, as *commodities* de energia, agricultura e indústria apresentaram efeito alavancagem, ou seja, as correlações condicionais respectivas tendem a crescer mais quando os ambos os mercados estão em baixa do que quando estão em alta. No que diz respeito aos *MRLM*, constatou-se uma relação positiva entre a volatilidade do mercado acionário e as correlações condicionais, com exceção dos metais preciosos. Além disso, as correlações condicionais entre *commodities* industriais e o S&P 500 sofreram influência de todas as crises citadas na análise, enquanto as *commodities* metais preciosos e agrícolas não tiveram suas correlações condicionais afetadas pela crise dos *subprime*.

Em determinadas publicações o foco da investigação se concentra única e exclusivamente no petróleo, *commodity* cujo mercado historicamente demonstrou ter capacidade suficiente para desequilibrar a economia mundial, dando origem a diversos estudos sobre a volatilidade desse bem no mercado financeiro e sua correlação com os demais mercados, por exemplo. De um ponto de vista mais teórico, Tokic (2015) decidiu investigar a forte queda de preços do petróleo na segunda metade do ano 2014 analisando a relação entre oferta e demanda da *commodity*, bem como outros fatores determinantes como a (des)regulação da produção ou a especulação financeira, testando a hipótese de eficiência de mercado para identificar se o choque negativo de preços no mercado de petróleo foi gerado por um “descolamento” entre oferta e demanda, no caso um excesso de oferta do bem. Para tal análise, o autor avaliou a evolução histórica da produção e do consumo de petróleo desde 2005 até 2014. Em seguida, o autor analisou a taxa de câmbio Euro/Dólar ao longo do mesmo período em paralelo à evolução do preço do petróleo. O diagnóstico surpreendeu apontando o câmbio como principal fator determinante da descendência dos preços do petróleo. O autor constatou que, tanto na crise de 2008 quanto na queda de preços em 2014, houve uma alta correlação entre o câmbio e o preço do petróleo. As oscilações no câmbio se deram por conta de divergências entre as trajetórias de crescimento dos EUA e da União Européia em ambos os períodos. A

importância do petróleo não só como bem mas como um ativo financeiro fez com que esse fosse utilizado como uma “aposta” contra o dólar: a desvalorização do Dólar frente ao Euro em 2008 fez com que o petróleo ficasse relativamente mais caro enquanto a desvalorização do Euro frente ao Dólar tornou o petróleo relativamente mais barato. Essa explicação foi considerada a mais crível para as alterações bruscas no preço do petróleo do que o desequilíbrio entre oferta e demanda, dado que o consumo e a produção de petróleo cresceram na mesma proporção no período em análise. O autor acrescentou ainda que as incertezas do mercado (sentimento negativo dos investidores) tiveram sua parcela de impacto nas variações de preço do bem em questão.

Com a mesma temática porém com a metodologia do *DCC-GARCH*, pode-se citar o trabalho desenvolvido por Antonakakis e Filis (2013), no qual examinaram a influência de preços de petróleo ao longo do tempo nos mercados de ações dos EUA, Reino Unido, Alemanha, Canadá e Noruega. Os três primeiros são países importadores de petróleo enquanto os dois últimos exportam o bem. Para isso os autores coletaram as séries mensais de retornos do principal índice de ações de cada país: Dow Jones (EUA); FTSE 100 (Reino Unido); DAX 30 (Alemanha); TSX (Canadá) e; OBX (Noruega), fora a série mensal de retornos do petróleo Brent. Os dados foram delimitados cronologicamente entre Janeiro de 1998 até Dezembro de 2011. Os autores elaboraram dois modelos *DCC-GARCH*, sendo que em um deles o índice Brent foi utilizado com variável explicativa dos índices de ações. Para avaliar a influência dos preços de petróleo, os autores criaram o indicador *OilEffects*, que calcula a variação percentual entre a correlação dos dois modelos ao longo do tempo⁵. Os resultados os levaram às seguintes conclusões: as mudanças nos preços de petróleo impactaram nas correlações entre os índices de ações dos países (exceto entre o índice TSX e o índice OBX) e, ao contrário do esperado, tal fato constatado independeu do país ser exportador ou importador de petróleo. Adicionalmente, aparentemente os choques de demanda agregada e de demanda precaucional (frente às incertezas da produção futura) no mercado de petróleo afetaram a correlação deste com os mercados de ações. Por outro lado, nada pôde ser comprovado em relação a choques do lado da oferta.

Anteriormente, Filis, Degiannakis e Floros (2011) já tinham desenvolvido um trabalho sob os mesmos moldes, modificando o grupo de países estudados selecionando os índices Dow Jones (EUA), AEX (Holanda), DAX30 (Alemanha) como países importadores de petróleo e os índices TSX60 (Canadá), MXICP35 (México) e Ibovespa (Brasil) como países exportadores

⁵ Para maiores detalhes ver Antonakakis e Filis (2013).

de petróleo. Nessa pesquisa a metodologia consistiu na aplicação do modelo *DCC-GARCH-GJR* em base mensal de dados no período entre Janeiro de 1987 e Setembro de 2009. A partir dos resultados obtidos, os autores comprovaram também que não houve diferença entre a correlação variante ao longo do tempo dos retornos dos preços de petróleo e dos retornos dos preços de ações em relação ao tipo de país em análise (exportador ou importador) pois os choques de demanda agregada que impactam o preço do petróleo foram causados por flutuações nos ciclos de negócios globais que, por sua vez, também influenciam os preços das ações no mesmo sentido, em contraste com expectativas *ex ante* dos autores. Além disso, choques de demanda precaucionária causados por ataques terroristas e guerras tiveram maior impacto na correlação do que choques de oferta gerados por cortes na produção por parte da Organização dos Países Exportadores de Petróleo (OPEP) ou por desastres naturais como furacões. A correlação entre os retornos de preços de ações e os retornos defasados de preços de petróleo tiveram sinal negativo em todos os eventos importantes, exceto na crise de 2008. Logo, em momentos turbulentos na economia, o petróleo não serviu de *hedge* para ações.

Chang, McAleer e Tansuchat (2013), assim como Sadorsky (2014) e Demiralay e Ulusoy (2014), fizeram uso de outros três modelos da família *GARCH* fora o *DCC*: o *CCC-GARCH*; o *VARMA-GARCH* e; sua versão assimétrica, o modelo *VARMA-AGARCH*. A metodologia do trabalho foi aplicada nas séries de retornos diários de preços dos índices de ações tais como: o FTSE100 (Londres, Inglaterra); o NYSE *composite* (Nova Iorque, EUA); o S&P500 *composite* e; o Dow Jones Industrials, além dos retornos diários de preços do petróleo Brent e do petróleo WTI, ambos subdivididos em três séries: *spot*, um mês a frente e futuro um mês a frente. A amostra abrangeu um espaço de tempo desde Janeiro de 1998 até Novembro de 2009.

Comparativamente, os autores constataram através dos números encontrados nos resultados a superioridade do modelo *DCC-GARCH* em relação ao modelo *CCC*, dado que este último não detectou a ocorrência de choques condicionais correlacionados entre mercados. Por outro lado, o modelo *DCC* mostrou que as correlações condicionais foram sempre significativas, principalmente a correlação condicional dinâmica entre retornos *forward* do petróleo Brent e retornos do FTSE100, que variaram muito durante o tempo. Em relação aos modelos *VARMA-GARCH* e *VARMA-AGARCH*: dos 24 vetores criados (6 preços de petróleo x 4 índices de ações) somente 2 estabeleceram relações significativas no primeiro e apenas 3 no segundo modelo. Desse modo, foi possível detectar *spillovers* de volatilidade dos retornos do índice FTSE100 para retornos um mês a frente do índice WTI e de volatilidade de retornos futuros do índice WTI para retornos do índice FTSE100. A constatação de efeitos assimétricos

nos choques de volatilidade sugeriu que o desempenho do modelo VARMA-AGARCH foi superior aos desempenhos dos demais modelos.

Ewing e Malik (2013), por sua vez, se propuseram a investigar o comportamento de volatilidade dos contratos futuros de ouro e de petróleo e como os retornos destes interagem entre si, dada a importância do ouro como investimento “seguro”. Os dados escolhidos pelos autores consistem em séries de retornos diários de preços de contratos futuros de ouro da COMEX (obtido na Bloomberg) e de petróleo da NYMEX (obtido no *U.S. Department of Energy*), datados entre Julho de 1993 e Junho de 2010. Foram aplicados dois modelos *GARCH* bivariados: um padrão e outro que inclui quebras estruturais, obtidas endogenamente a partir do algoritmo da soma acumulada iterada dos quadrados modificada ou *modified ICSS*. O principal achado desse trabalho foi constatar a importância de se levar em conta nos modelos *GARCH* as quebras estruturais das séries de retornos analisadas. Os modelos sem quebra não detectaram influência direta dos choques passados e da volatilidade passada de um mercado em outro, além de superestimarem a persistência de choques e volatilidade passadas e subestimarem o custo mínimo de *hedge* dos portfólios contendo ouro e petróleo. Os modelos com quebra, por sua vez, foram capazes de corrigir tais falhas, comprovando a influência e interação entre os retornos de ouro e de petróleo ao longo do período estudado.

3. METODOLOGIA

3.1. Modelo DCC-GARCH

O modelo *DCC-GARCH* proposto por Engle (2002) foi selecionado com o intuito de estimar a correlação condicional entre os índices de *commodities* e o índice S&P500 ao longo do intervalo de tempo escolhido, dada a superioridade desse modelo em relação ao *CCC-GARCH*, constatada por Sadorsky (2014) e Chang, McAleer e Tansuchat (2013). Por se tratar de um modelo *GARCH* multivariado, além da variância condicional se faz necessária a estimação das covariâncias condicionais entre as variáveis analisadas. A matriz de covariância é definida na Equação (1):

$$H_t = D_t R_t D_t, \quad (1)$$

onde R_t é matriz de correlação variante com o tempo, que precisa ser inversível e positiva definida, e $D_t = \text{diag}(h_{11,t}, \dots, h_{nn,t})$, ou seja, uma matriz diagonal composta pelos desvios-padrão condicionais obtidos através da modelagem *GARCH* univariada estimada previamente. Especificamente nesse trabalho, escolheu-se para cada série um modelo *ARMA-GARCH* univariado de acordo com Critério de Informação de Schwarz *et al.* (1978) (SIC) ou *Bayesian Information Criteria (BIC)*, ou seja, foram estimadas também as médias condicionais dessas séries.

Antes da modelagem de média e variância condicionais, foi verificado se os fatos estilizados de séries de retornos financeiras se aplicavam aos dados selecionados. Para verificar a estacionariedade dos retornos dos preços dos índices, optou-se pela aplicação do teste de raiz unitária de Dickey e Fuller (1979). Quanto à fraca dependência linear e à forte dependência não linear, utilizou-se o teste de autocorrelação de Ljung e Box (1978) tanto nos retornos dos preços quanto nos quadrados destes. O formato da distribuição foi avaliada pelo teste de normalidade dos resíduos de Jarque e Bera (1980) enquanto a ocorrência de heterocedasticidade condicional foi checada através do teste *ARCH-LM*.

O Método *ARMA* pode ser demonstrado pelas Equações (2a) e (2b) abaixo:

$$\Phi(L)\mathbf{y}_{i,t} = \boldsymbol{\mu}_i + \Theta(L)\boldsymbol{\varepsilon}_{i,t} \quad (2a)$$

$$\boldsymbol{\varepsilon}_{i,t} = \mathbf{H}_t^{\frac{1}{2}}\mathbf{v}_{i,t}\mathbf{v}_{i,t} \sim Std\ t(0,1), \quad (2b)$$

onde $\mathbf{y}_{i,t}$ é o vetor dos retornos de preços das séries $i = 1, \dots, N$ em $t = 1, \dots, T$, $\boldsymbol{\mu}_i$ é um valor constante, L é o operador defasagem nos polinômios autorregressivo $AR(r)$ ($\Phi(L) = 1 - \varphi_1L - \dots - \varphi_rL^r$) e de média móvel ou *moving average* $MA(u)$ ($\Theta(L) = 1 + \theta_1L + \dots + \theta_uL^u$) e $\boldsymbol{\varepsilon}_{i,t}$ é o vetor dos termos de erro, cuja Equação (2b) acima leva em consideração a heterocedasticidade condicional, representada por $\mathbf{H}_t^{\frac{1}{2}}$, bem como o excesso de curtose dado que o vetor dos termos estocásticos \mathbf{v}_t do modelo segue uma distribuição t de Student.

Para as variâncias condicionais das séries do GSCI e dos índices de Agricultura e Metais Industriais optou-se pelo uso do modelo *GARCH* padrão simétrico de Bollerslev (1986). Para as demais o modelo considerado mais adequado foi o *EGARCH* de Nelson (1991) descrito pela Equação (3):

$$\ln h_{it}^2 = \omega_i + \sum_{j=1}^q \alpha_{ij} \varepsilon_{it-1}^2 + \gamma_{ij} \left(|\varepsilon_{it-1}^2| - E(|\varepsilon_{it-1}^2|) \right) + \sum_{j=1}^p \beta_{ij} \ln h_{it-1}^2, \quad (3)$$

sendo que o parâmetro α_{ij} representa a reação da variância aos quadrados dos choques (erros) passados (ε_{it-1}^2), o parâmetro β_{ij} corresponde à persistência do impacto da variância passada (h_{it-1}^2) sobre a variância atual e o parâmetro $\gamma_{i,t}$ capta o efeito alavancagem ou efeito assimétrico, isto é, quando os choques negativos têm maior impacto sobre a variância condicional do que os choques positivos de mesma magnitude. Vale lembrar que, quando se trata do modelo *GARCH* simétrico de Bollerslev (1986), o termo $\gamma_{i,t}$ não existe. Os modelos *GARCH* univariados são estimados pelo Método de Máxima Verossimilhança (MMV).

Para garantir as propriedades necessárias da matriz \mathbf{R}_t (ser inversível e positiva definida), pode-se modelar um processo *proxy* \mathbf{Q}_t definido da seguinte maneira:

$$\mathbf{Q}_t = (1 - a - b)\bar{\mathbf{Q}} + a\mathbf{v}_{t-1}\mathbf{v}'_{t-1} + b\mathbf{Q}_{t-1}, \quad (4)$$

no qual a e b são escalares cuja soma precisa ser inferior a 1 para garantir que \mathbf{Q}_t seja estacionária e positivamente definida. $\bar{\mathbf{Q}}$ é a matriz incondicional dos erros padronizados (\mathbf{v}_t). Por esse procedimento, a matriz de correlação \mathbf{R}_t apresenta a forma abaixo:

$$\mathbf{R}_t = \text{diag}(\mathbf{Q}_t)^{-\frac{1}{2}} \mathbf{Q}_t \text{diag}(\mathbf{Q}_t)^{-\frac{1}{2}} \quad (5)$$

Assim como no modelo univariado, o modelo *DCC-GARCH* tem seus parâmetros estimados a partir do Método de Máxima Verossimilhança. A função de Log-verossimilhança ou *Loglikelihoodfunction* (LL) é composta conforme a seguir:

$$\begin{aligned} LL &= \frac{1}{2} \sum_{i=1}^T \left(n \log \frac{2}{\pi} + 2 \log |\mathbf{D}_t| + \log |\mathbf{R}_t| + \mathbf{v}_t' \mathbf{R}_t^{-1} \mathbf{v}_t \right) \\ &= \frac{1}{2} \sum_{i=1}^T \left(n \log \frac{2}{\pi} + 2 \log |\mathbf{D}_t| + \boldsymbol{\varepsilon}_t' \mathbf{D}_t^{-1} \mathbf{D}_t^{-1} \boldsymbol{\varepsilon}_t \right) - \frac{1}{2} \sum_{i=1}^T \left(\mathbf{v}_t' \mathbf{v}_t + \log |\mathbf{R}_t| + \mathbf{v}_t' \mathbf{R}_t^{-1} \mathbf{v}_t \right) \quad (6) \\ &= LL_V(\eta_1) + LL_R(\eta_1, \eta_2), \end{aligned}$$

sendo $LL_V(\theta_1)$ o componente de volatilidade com parâmetros θ_1 e $LL_R(\theta_1, \theta_2)$ o componente de correlação com parâmetros θ_1 e θ_2 . Desse modo, o processo de maximização da função se dá em dois passos: primeiro para estimar as variâncias condicionais (modelo *EGARCH* - univariado) e, em seguida, para estimar as correlações condicionais (modelo *DCC-GARCH* - multivariado).

3.2. Métricas de Hedge

Com a finalidade de analisar as propriedades de *hedge* de cada índice e seguindo o exemplo de artigos como o de Sadorsky (2014) e outros previamente citados no Capítulo 2, três métricas diferentes foram aplicadas nos dados. São elas: a Relação temporal de *Hedge*, a Taxa de *Hedge* e o Peso ótimo de portfólio para *hedge* de dois ativos. O primeiro basicamente verifica os momentos em que a correlação condicional ficou abaixo de zero em relação ao todo, o segundo se trata de uma métrica que calcula o quanto se gasta para se usar um determinado índice para se proteger de perdas do índice S&P500 e o terceiro estima a proporção ótima entre dois índices para estabelecer a melhor forma de *hedge* possível.

3.2.1. Relação temporal de Hedge

O conceito desse indicador é, simplesmente, verificar a proporção de observações com correlação condicional negativa em relação à quantidade total de observações da amostra, permitindo verificar o quão eficientes os índices de *commodities* foram durante determinado período como um instrumento de *hedge* para o índice S&P500. A fórmula para obtenção dessa relação consiste na Equação 7 a seguir:

$$r = \left(\frac{\#n_{hedge}}{n} \right), \quad (7)$$

onde $\#n_{hedge}$ é o número de observações com valor abaixo de zero e n é o tamanho da amostra. Aplica-se essa razão para todo o período e para cinco sub-períodos escolhidos de acordo com o principais eventos ocorridos: de 1999 à 2002 (a bolha da internet e o atentado de 11 de Setembro), de 2003 à 2007 (guerra do Iraque e o momento da financialização), 2008 (crise dos *subprime*), de 2009 até o primeiro semestre de 2014 (pós-crise dos *subprime* e crise da dívida soberana europeia), segundo semestre de 2014 até o primeiro semestre de 2017 (queda geral do preço das *commodities* e continuação da crise da dívida soberana europeia). Calcular essa medida para esses sub-períodos permite uma melhor avaliação das possibilidades não apenas de *hedge* mas também de *safe haven* em meio de diferentes momentos da economia.

3.2.2. Taxa de Hedge

Kroner e Sultan (1993) propuseram um método para obter a taxa de *hedge* capaz de minimizar o risco, tomando posições nos mercados a vista (*spot*) e no mercado futuro, referente a um mesmo ativo. No trabalho os autores aplicaram o modelo a diversas moedas, cotadas em dólar. O método pressupõe que os riscos de ambos os mercados não são constantes e que existe uma relação de longo prazo entre o preço *spot* e o preço futuro do ativo. Como resultado do modelo, a solução ótima encontrada para a minimização de risco através de uma taxa de *hedge* variante com o tempo leva em consideração momentos condicionais como variância e covariância, conforme na equação a seguir:

$$\hat{\beta}_{ij,t} = \frac{\hat{h}_{ij,t}}{\hat{h}_{j,t}^2} \quad (8)$$

onde $\hat{h}_{ij,t}$ é a covariância entre i e j em t e $\hat{h}_{j,t}^2$ é a variância de j em t . A taxa de *hedge* $\hat{\beta}_{ij,t}$ significa que cada dólar investido pelo agente tomando posição de compra (*long*) no ativo i pode ser protegido por β dólares investidos numa posição de venda (*short*) no ativo j . Cabe ressaltar que, caso o β seja negativo, isso significa que o ideal será que o agente inverta as posições tomadas em cada ativo.

3.2.3. Peso ótimo de portfólio

Kroner e Ng (1998) propuseram o uso da fórmula do peso ótimo obtido a partir do problema de minimização de risco de carteira com base em Markowitz (1952) para conseguir os pesos ótimos de cada ativo para um portfólio de dois ativos ao longo do tempo, respeitando as seguintes premissas: o retorno esperado para cada ativo é igual a zero e não há restrições no problema, salvo o fato de a soma dos pesos dos dois ativos ser igual a 1. Exemplificando, se o peso do índice S&P500 num portfólio contendo esse ativo e o GSCI for igual a 0,3, então 30% do valor da carteira deverá ser investido no S&P500 e o restante no GSCI para desempenhar o *hedge* da melhor forma possível. Esses valores são obtidos pela expressão abaixo:

$$w_{ij,t} = \frac{\hat{h}_{j,t}^2 - \hat{h}_{ij,t}}{\hat{h}_{i,t}^2 - 2\hat{h}_{ij,t} + \hat{h}_{j,t}^2} \quad (9a)$$

$$w_{ij,t} = \begin{cases} 0, & \text{se } w_{ij,t} < 0 \\ w_{ij,t}, & \text{se } 0 \leq w_{ij,t} \leq 1, \\ 1, & \text{se } w_{ij,t} > 1 \end{cases} \quad (9b)$$

onde $w_{ij,t}$ é o peso do ativo i num portfólio composto pelos ativos i e j no tempo t .

3.3. Dados Empíricos


Os dados selecionados consistem nos retornos diários dos índices S&P-GSCI e S&P500, bem como os subíndices do primeiro, correspondentes ao período entre Janeiro de 1999 e Junho

de 2017, obtidos na base de dados da própria Standard and Poor's. Esse intervalo de tempo nos permite avaliar o comportamento da correlação condicional entre os preços de *commodities* e ações de um modo geral tanto em momentos de estabilidade no mercado financeiro quanto em situações de estresse, proporcionadas seja por crises de ordem financeira ou por crises de ordem geopolítica. Os índices selecionados são compostos por ativos de ampla liquidez relacionados a diversas atividades econômicas, refletindo de forma substancial o dinamismo da economia mundial.

O S&P-GSCI (originalmente denominado índice de *commodities* Goldman Sachs) foi criado em 1991 pelo banco de investimento Goldman Sachs com o objetivo de medir a performance dos mercados futuros de *commodities* e servir como instrumento financeiro para os investidores. Desde 2007, o índice tornou-se propriedade da Standard and Poor's, que por sua vez passou a publicá-lo. Em particular, o índice S&P-GSCI tem como base para o cálculo a produção mundial, ou seja, o peso atribuído a cada *commodity* leva em consideração a importância desta na atividade econômica do mundo, o que justifica o fato de *commodities* de energia como o petróleo e *commodities* de agricultura como o trigo terem maior participação na composição do valor do índice. Os principais setores da economia abrangidos pelo indicador são: energia, metais preciosos, agricultura, pecuária e metais industriais. Dito isso, dos subíndices S&P-GSCI foram selecionados cinco: *Energy*, *Precious Metals*, *Agriculture*, *Livestock* e *Industrial Metals*. Espera-se que os subíndices consigam identificar a origem da volatilidade e de correlação obtidos entre o índice S&P-GSCI e o índice S&P500. O índice S&P-GSCI *Agriculture* tem em sua composição as *commodities* trigo, milho, café, açúcar, cacau e algodão. Por sua vez, o índice S&P-GSCI *Livestock* inclui animais como suíno, boi gordo e bezerro. O índice S&P-GSCI *Energy* é composto por insumos como o petróleo e o gás natural, enquanto no índice S&P-GSCI *Precious Metals* estão incluídos ouro e prata e o índice S&P-GSCI *Industrial Metals* inclui metais como alumínio, zinco, níquel, cobre e chumbo.

O índice Standard and Poor's 500 ou simplesmente S&P500 se baseia na capitalização de mercado das 500 maiores empresas dos EUA, servindo como um dos principais indicadores da economia norte-americana. A iniciativa de criar índices de ações da bolsa Dow Jones começou em 1927 e passou a englobar as 500 maiores empresas a partir de 1957, o que proporciona um vasto registro de informação sobre a história do mercado financeiro. Nesse trabalho este indicador servirá de *proxy* para o desempenho econômico do mundo. A partir da Figura 1 pode-se ter uma ideia da interação dos movimentos de preços do S&P500 e do S&P-GSCI. Nota-se que tanto entre 2007 e 2009 quanto entre 2011 e 2016 os índices apresentaram tendências distintas.

Figura 1 - Evolução dos índices S&P500 versus S&P-GSCI



Fonte: O autor, 2017.

A Tabela 1 descreve as principais estatísticas descritivas dos retornos de preços das séries selecionadas. Nota-se que o índice de Energia registrou o maior desvio-padrão enquanto o índice de Pecuária apresentou o menor valor. O índice S&P500 teve a maior variação positiva diária (11,6%) em 13 de outubro de 2008, logo após os EUA, Reino Unido e as principais nações da economia mundial anunciarem seus planos de resgate das instituições financeiras para impedir colapso do sistema financeiro. O índice de Energia sofreu a maior queda (-13,4%) em 24 de setembro de 2001, momento de recessão econômica que por sua vez gerou uma expectativa de queda na demanda mundial de petróleo, provocando forte declínio dos preços futuros dessa *commodity*. Em adição, com exceção do índice de Agricultura, todas as séries de retornos registraram estacionariedade, existência de efeitos ARCH (heterocedasticidade) e assimetria negativa porém com baixo valor absoluto. Por outro lado, não houveram exceções em relação a curtose (todos os valores foram superiores a 3, o valor de curtose da distribuição normal) indicando que as distribuições dos dados apresentaram “caudas pesadas”.

Tabela 1 - Estatísticas Descritivas - Séries de retornos

	S&P500	GSCI	Agri.	Ener.	M. Ind.	Pec.	M. Prec.
Média	2,2E-04	3,3E-04	1,9E-04	4,8E-04	3,0E-04	2,0E-04	3,8E-04
D.Padrão	0,012	0,015	0,013	0,020	0,014	0,009	0,012
Máximo	0,116	0,075	0,074	0,103	0,079	0,047	0,092
Mínimo	-0,090	-0,088	-0,074	-0,134	-0,087	-0,042	-0,096
Assimetria	-0,002	-0,124	0,006	-0,054	-0,129	-0,057	-0,118
Curtose	11,247	5,445	5,437	5,217	5,897	3,726	8,924
JB	13.22	1.175	1.155	959	1.645	105,28	6.832
	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Q(10)	57,121	14,395	11,638	16,736	30,829	33,972	11,891
	(0,000)	(0,156)	(0,310)	(0,080)	(0,001)	(0,000)	(0,292)
Q ² (10)	3.624	1.359	1.007	1	1.705	338	387
	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
ARCH(10)	1.192	565	450	439	640	185	227
	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
ADF	-16,476	-15,476	-16,537	-15,380	-15,708	-16,015	-16,814
	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)

Notas: JB se trata do resultado do teste de Jarque-Bera. Q(10) e Q²(10) se referem as estatísticas do teste de Ljung-Box com 10 defasagens para os retornos e os quadrados destes, respectivamente. ARCH equivale ao multiplicador de Lagrange do teste ARCH com 10 defasagens. ADF é a estatística do teste de Dickey-Fuller aumentado. Os p-valores correspondentes aos testes estão entre parênteses.

Fonte: O autor, 2017.

4. ANÁLISE DE RESULTADOS

4.1. Estimação do modelo *DCC-GARCH*

A Tabela 2 exhibe os resultados da estimação das Equações (3) e (4). Vale lembrar que tanto no caso do GSCI quanto no dos índices de Agricultura e de Metais Industriais, foi utilizado o modelo *GARCH* padrão de Bollerslev (1986) por se adequar melhor ao critério *BIC*. A aplicação do método ARMA se fez necessária em apenas alguns casos. Vale destacar que o parâmetro α obteve sinal negativo para os modelos referentes ao S&P500 e aos índices de Energia e Pecuária, sendo o primeiro com o maior valor absoluto registrado. Quanto ao β , todos os modelos apresentaram valores próximos a 1 para esse parâmetro indicando forte persistência dos choques na variância condicional da cada série. Além disso, os parâmetros a e b do *DCC-GARCH*(1,1) foram, na média, similares aos valores de α e β registrados em cada série univariada.

Tabela 2 – Resultados das estimações

Coefficiente	S&P500	GSCI	Agri.	Ener.	M. Ind.	Pec.	M. Prec.	DCC
μ	3,8E-04 (0,000)						4,6E-04 (0,000)	
ϕ_1						0,056 (0,000)		
θ_1	-0,063 (0,000)		0,046 (0,002)		-0,055 (0,000)			
ω	-0,148 (0,000)	1,0E-05	0,000 (0,034)	-0,032	1,0E-05	-0,121	-0,053	
α_1	-0,258 (0,000)	0,038 (0,000)	0,047 (0,000)	-0,030 (0,000)	0,042 (0,000)	-0,028 (0,000)	0,030 (0,000)	
α_2	0,116 (0,000)							
β_1	0,985 (0,000)	0,959 (0,000)	0,947 (0,000)	0,996 (0,000)	0,953 (0,000)	0,999 (0,000)	0,994 (0,000)	
β_2						-0,110 (0,000)		
β_3						0,097 (0,000)		
γ_1	-0,078 (0,003)			0,091 (0,000)		0,083 (0,000)	0,095 (0,000)	
γ_2	0,193 (0,000)							
A								0,029 (0,000)
B								0,969 (0,000)
g.l.	7,950 (0,000)	10,047 (0,000)	10,150 (0,000)	9,422 (0,000)	8,892 (0,000)	20,200 (0,000)	4,609 (0,000)	9,385 (0,000)


Nota: g.l. são os graus de liberdade para as distribuições t de Student e t de Student multivariada.

Fonte: O autor, 2017.

As distribuições escolhidas para modelagem dos erros tanto nos modelos *GARCH* (univariados) quanto no modelo *DCC-GARCH* (multivariado) foram a *t* de Student e a *t* de Student multivariada, respectivamente. As equações dos modelos estimados tanto para cada série quanto para o *DCC-GARCH* como um todo assim como os testes de consistência aplicados a estes estão no Apêndice. Todos os coeficientes foram estatisticamente significativos ao nível de 5% de significância. Os p-valores estão entre parênteses.

As figuras contendo os gráficos das correlações condicionais dinâmicas entre o índice S&P500 e cada índice de *commodity* são mostradas no Apêndice. Observa-se em todas a presença de alta volatilidade nas correlações condicionais, conforme mencionado na literatura anteriormente apresentada no Capítulo 2. Antes de 2005, na maior parte do tempo os valores registrados foram negativos exceto para os índices de Metais Industriais e de Pecuária. Mais adiante, entre 2006 e 2008, o ascensão das correlações condicionais dos índices, salvo o de Metais Preciosos, refletiu o processo de financialização de *commodities*, tornando os derivativos correspondentes menos interessantes para diversificação de risco em portfólios contendo ações.

Figura 2 - S&P500 versus S&P-GSCI



Fonte: O autor, 2017.

Particularmente em 2008, antes da falência do banco de investimento Lehman Brothers em 15 de setembro, todas as correlações condicionais registradas apresentaram valores negativos. O GSCI, por exemplo, era negativamente correlacionado com o S&P500 em Maio do mesmo ano e seguiu em queda até chegar ao valor mínimo obtido em 2008 de $-0,408$, no

dia 3 de Julho. Cerca de dois meses e meio depois, em 15 de setembro a correlação condicional ascendeu para $-0,09$ e estabeleceu tendência de alta a partir do mês seguinte. Em meio às incertezas de 2008, o padrão de comportamento entre os índices de *commodities* e S&P500 se alterou no curto prazo. A Tabela 3 mostra as estatísticas das correlações condicionais estimadas pelo modelo *DCC-GARCH* referentes a todo o período em análise e, numa tabela logo abaixo, ao ano de 2008 somente. Comparando os valores mínimo e máximo, o índice de Agricultura teve o menor decaimento durante todo o intervalo de tempo analisado, enquanto o de Pecuária obteve o menor decréscimo em 2008. No mais, todos os índices registraram seus valores mínimos antes da falência do banco Lehman Brothers e todas as respectivas correlações condicionais passaram a ascender após essa data, indicando um possível “efeito manada” no qual os investidores buscaram se proteger das perdas no mercado de ações aplicando seus recursos no mercado futuro de *commodities* cujos preços estavam em alta. Coincidência ou não, depois de 2008 as correlações condicionais atingiram seus maiores valores, o que significa que o fenômeno de financialização persistiu após a crise. Todavia, cabe destacar que a partir de 2011 as correlações condicionais não mantiveram uma tendência de alta regular, corroborando com Boyrie e Pavlova (2016). De qualquer maneira, as *commodities* deixaram de ser alternativas de *hedge* para o mercado acionário.

Tabela 3 - Correlações condicionais - Estatísticas

1999-2017	Média	Desv.Pad.	Mín.	Máx.
GSCI	0,186	0,261	-0,409	0,714
Agricultura	0,117	0,161	-0,280	0,551
Energia	0,167	0,262	-0,423	0,681
M.Industriais	0,247	0,182	-0,288	0,688
Pecuária	0,082	0,136	-0,357	0,438
M.Preciosos	0,010	0,214	-0,647	0,629
Apenas 2008	Média	Desv.Pad.	Mín.	Máx.
GSCI	0,031	0,256	-0,408	0,500
Agricultura	0,054	0,163	-0,208	0,363
Energia	0,024	0,260	-0,423	0,505
M.Industriais	0,121	0,179	-0,288	0,407
Pecuária	0,101	0,137	-0,196	0,358
M.Preciosos	-0,112	0,170	-0,408	0,233

Fonte: O autor, 2017.

Anos depois, no começo de 2014 a correlação condicional entre o índice S&P500 e o GSCI se situava em torno de 0,3. Esse valor decresceu até o final do primeiro semestre do

mesmo ano, quando no semestre seguinte os preços da maioria das *commodities* caíram fortemente. Essa mudança pode ser explicada pela apreciação do Dólar norte-americano frente ao Euro como consequência da crise da dívida soberana europeia (Ver Tokic (2015) que examina o caso do petróleo). Novamente, as correlações condicionais se elevaram e as *commodities* perderam sua capacidade de *hedge* para ações, salvo o índice de Metais Preciosos que, por sua vez, se manteve com correlações condicionais negativas na maior parte do tempo.

Vale destacar que tanto antes da crise dos *subprime* em 2008 quanto antes da queda geral dos preços das *commodities* em meados de 2014 os números das correlações condicionais estavam em declínio, denotando um padrão adequado para a realização de *hedge* de ações com *commodities*. Por outro lado, analisando os valores mais recentes, nota-se a presença do fenômeno da financialização em quase todos os índices exibindo correlações condicionais positivas com o índice S&P500, exceto o de Metais Preciosos. Pode-se dizer que este último índice continua sendo um investimento seguro para momentos de crise, inclusive servindo de *safe haven* em 2008 conforme afirmado anteriormente por Creti, Joëts e Mignon (2013). Outrossim, pode-se afirmar que a financialização não se trata de um fenômeno passageiro.

No que se refere às correlações condicionais estimadas entre *commodities*, na média, os valores são todos positivos em relação a todo o período em análise. O mesmo acontece em relação ao ano de 2008 apenas (Vide Tabela 8 no Apêndice). Ademais, todas as correlações condicionais médias registradas superaram expressivamente as médias correspondentes ao período inteiro em análise. O valor mais baixo entre as mínimas ocorreu entre os índices de Metais Preciosos e de Pecuária (-0,352) em 8 de Setembro de 2016, enquanto o maior valor dos máximos alcançados ocorreu entre os índices de Energia e de Metais Industriais (0,781) em 5 de Julho de 2012. Vale destacar que nenhum dos dois resultados aconteceram em 2008.

Curiosamente, o índice com o qual o de Agricultura apresentou melhores possibilidades de *hedge* foi o de Pecuária, haja visto que ambos costumam ser produzidos em conjunto. Por outro lado, o índice de Metais Preciosos por sua vez se mostrou uma boa possibilidade de *hedge* para o índice de Pecuária, dado que esta combinação apresentou os menores valores para todas as medidas. Similar aos resultados encontrados em Manera, Nicolini e Vignati (2013), as correlações condicionais entre o índice de Agricultura e o índice de Energia em 2008 dobraram em relação à média registrada entre 1999 e 2017.

Limitando a análise para as estatísticas descritivas das correlações condicionais obtidas no *DCC-GARCH* e aplicando categoricamente as definições de Baur e Lucey (2010), poder-se-ia afirmar que nenhum ativo serviu de *hedge* para o outro, dado que todas as correlações condicionais foram, na média, positivas em relação a todo o período analisado. Em

contrapartida, poder-se-ia considerar que o índice de Metais Preciosos foi um “porto seguro” ou safe haven para o índice S&P500, pois apesar de ter registrado um valor médio de correlação condicional positivo entre 1999 e 2017, em 2008 a correlação condicional entre esses dois ativos foi, na média, negativa.

4.2. Resultados das métricas de *Hedge*

Primeiramente, pode-se afirmar que os números obtidos no cálculo da Equação (7) corroboraram com as observações oriundas das estatísticas descritivas das correlações condicionais. Além de trabalhar com intervalos de tempo menores e específicos, calcularam-se valores desse indicador referentes somente ao ano de 2008, em base bimestral, no qual houveram as maiores oscilações de correlações condicionais. A Tabela 4 disponibiliza os dados em dois painéis. No primeiro (Painel A) os números correspondem a todo o período da análise (de 1999 a 2017) e às sub-amostras delimitadas anteriormente no Capítulo 3. No segundo (Painel B) os valores apresentados se referem unicamente aos seis bimestres do ano de 2008.

Tabela 4 - Relação temporal de *hedge*

Painel A	1999-2017	1999-2002	2003-2007	2008	2009-2014.1	2014.2-2017
GSCI	0,242	0,322	0,513	0,409	0,029	0,018
Agricultura	0,252	0,425	0,297	0,452	0,144	0,079
Energia	0,279	0,353	0,589	0,417	0,048	0,040
M. Industriais	0,079	0,122	0,121	0,258	0,005	0,028
Pecuária	0,273	0,297	0,439	0,270	0,176	0,143
M. Preciosos	0,492	0,636	0,410	0,631	0,267	0,803
Painel B	Jan-Fev	Mar-Abr	Mai-Jun	Jul-Ago	Set-Out	Nov-Dez
GSCI	0,366	0,000	0,672	1,000	0,409	0,000
Agricultura	0,804	0,000	0,537	0,930	0,455	0,000
Energia	0,390	0,000	0,693	1,000	0,409	0,000
M. Industriais	0,000	0,000	0,450	1,000	0,136	0,000
Pecuária	0,244	0,000	0,317	0,860	0,455	0,000
M. Preciosos	0,073	0,238	0,929	1,000	1,000	0,488

Fonte: O autor, 2017.

Nota-se que o índice de Metais Preciosos registrou correlação condicional negativa com o índice S&P500 em praticamente 50% de todo o período. Em contraste, o índice de Metais Industriais se mostrou ser o menos adequado para estratégias de *hedge* com ações. Não por acaso os principais respectivos metais de cada índice, o ouro e o cobre, são demandados por

motivos deveras distintos na economia. O ouro é mais demandado como reserva de valor, utilizado pelos bancos centrais ocasionalmente para influenciar mudanças nas taxas de câmbio, do que como insumo na indústria, haja vista que os fabricantes de jóias, por exemplo, reciclam boa parte do ouro utilizado. Diferentemente, o cobre é amplamente consumido por diversos setores industriais e sua demanda varia de acordo com o desempenho da atividade econômica, considerado por esse motivo um previsor dos ciclos de negócios (Vide Choi e Hammoudeh (2010)). Com exceção do índice de Metais Preciosos, todos os índices apresentaram o comportamento similar: crescimento da relação temporal de *hedge* de 1999 até 2008 e decréscimo de 2009 em diante.

A partir do Painel B, observa-se que nos terceiro e quarto bimestres, houve um forte aumento de correlações condicionais negativas em todos os índices de commodities, chegando a haver 100% de *hedge* no quarto bimestre salvo os índices de Agricultura e Pecuária. Logo após, com a eclosão da crise no mercado financeiro em Setembro de 2008, os valores de todos os índices dispararam, fazendo a relação temporal de *hedge* chegar a zero no último bimestre, com exceção do índice de Metais Preciosos.

A Tabela 5 exibe as estatísticas descritivas obtidas a partir do cálculo da Equação (8). De acordo com as médias obtidas, o agente pode se proteger de uma posição de compra de 1 dólar no índice S&P500 tomando uma posição de venda de 15 *cents* no GSCI. Em termos absolutos, o índice de *commodity* considerado em média mais barato foi o de Metais Preciosos (1,6 *cents* por dólar), diferentemente do trabalho de Mensi *et al.* (2013), no qual o trigo foi a *commodity* com o menor custo de *hedge* em relação ao S&P500. Em contrapartida, o índice de Metais Industriais (20,6 *cents* por dólar) foi o mais caro. Importante ressaltar que, no caso do índice de Metais Preciosos, a estratégia ideal seria tomar nesse índice uma posição de compra e uma posição de venda no índice S&P500 devido ao valor negativo do β . Quanto ao desvio-padrão, o custo de *hedge* com maior variação ao longo do tempo foi o GSCI (0,221) enquanto o índice de Agricultura registrou o menor valor (0,153). Durante a crise, para todos os casos o comportamento da taxa de *Hedge* foi similar ao das correlações condicionais: uma forte queda seguida de uma forte ascensão.

Tabela 5 - Taxa de *Hedge* de Kroner e Sultan

	Média	Desv. Pad.	Mín.	Máx.
GSCI	0,150	0,221	-0,399	1,033
Agricultura	0,097	0,153	-0,415	0,927
Energia	0,103	0,171	-0,368	0,795
M. Industriais	0,206	0,188	-0,373	1,308
Pecuária	0,109	0,202	-0,443	1,140
M. Preciosos	-0,016	0,209	-1,002	0,719

Fonte: O autor, 2017.

A Tabela 6 exibe as estatísticas descritivas obtidas a partir do cálculo da Equação (9). Em média, numa carteira incluindo o índice de S&P500 e o GSCI, o primeiro teria peso de aproximadamente dois terços (0,67) ante um terço do GSCI (0,33). A combinação na qual o índice S&P500 registrou o maior peso médio (e a menor oscilação de peso) foi com o índice de Energia. O menor peso médio do S&P500 se deu num portfólio com o índice de Pecuária. Naturalmente, os valores 1 e 0 foram registrados com maior frequência depois de 2008, os quais denotam inviabilização de *hedge*.

Tabela 6 - Peso ótimo de portfólio de Kroner e Ng

	Média	Desv. Pad.	Mín.	Máx.
GSCI	0,673	0,219	0	1
Agricultura	0,596	0,225	0,031	1
Energia	0,802	0,166	0,135	1
M. Industriais	0,649	0,261	0	1
Pecuária	0,464	0,216	0	0,988
M. Preciosos	0,579	0,216	0,078	1

Fonte: O autor, 2017.

CONCLUSÕES

Os resultados alcançados mostram o comportamento dos índices de *commodities* como instrumento de *hedge* ao índice S&P500 durante as crises dos *subprime* e da dívida soberana europeia, bem como no declínio generalizado dos preços das *commodities*. Os resultados mostram o aumento das correlações condicionais dos índices a partir de 2004 e os movimentos abruptos de queda meses antes da eclosão da crise em setembro de 2008, sinalizando a fuga do mercado acionário por parte dos investidores vendo o mercado de *commodities* como refúgio para amenizar perdas, e logo em seguida a chegada da crise no mercado de *commodities*, fazendo as correlações condicionais dispararem alcançando novos patamares. Nos anos seguintes, observam-se menos oscilações, salvo duas fortes variações pontuais: uma em meados de 2011 e outra no final de 2013, refletindo a crise do Euro. Ademais, pode-se destacar que, na queda generalizada dos preços das *commodities* o cenário se inverte: nesse momento é o índice S&P500 que se encontra em ascensão.

Pelas estatísticas descritivas, pode-se afirmar que o índice de Metais Preciosos serviu de *safe haven* para o S&P500 durante a crise de 2008 e nenhum índice serviu de *hedge* para ações, segundo os conceitos apresentados de Baur e Lucey (2010). Entre as *commodities*, chamou atenção o fato de o índice de Pecuária ser pouco correlacionado com os índices de Metais Preciosos e de Agricultura, principalmente este último dada a interatividade e dependência da produção de ambos os setores.

No que se refere à relação temporal de *hedge*, pôde-se comprovar a eficiência do índice de Metais Preciosos tanto em momentos de crise quanto em momentos de relativa tranquilidade no sentido de proteger os investidores contra perdas no mercado acionário. Em contrapartida, o índice de Metais Industriais se mostrou o menos eficiente nesse aspecto. O mesmo se observou nos resultados da Taxa de *Hedge*, onde o índice de Metais Preciosos se mostrou ser, em média, o mais barato para se proteger num portfólio com recursos alocados em ações, ao passo que o índice de Metais Industriais foi, na média, o mais caro.

Quanto ao peso ótimo de portfólio, concluiu-se que para compor uma carteira bem equilibrada dois terços dos recursos precisam estar aplicados no índice S&P500 para um terço no S&P-GSCI. Entre os subíndices, o índice de Energia registrou a menor oscilação ao longo do tempo e o menor peso em relação ao S&P500. Esses últimos resultados podem servir de base para futuras investigações quanto às possíveis combinações de carteiras com ações e *commodities* em modelos de otimização minimizando riscos via *hedge*.

REFERÊNCIAS

- AIELLI, G. P. Dynamic conditional correlation: on properties and estimation, *Journal of Business & Economic Statistics*, Taylor & Francis, n. 31, p. 282–299, 2013.
- AIUBE, F. A. L. *Modelos Quantitativos em Finanças com enfoque em commodities*. [S.l.]: Bookman, 2013.
- ALEXANDER, C.; CHIBUMBA, A. *Orthogonal GARCH: an empirical validation in equities, foreign exchange and interest rates*. School of Mathematical Sciences Discussion Paper, Sussex University, 1997.
- ANTONAKAKIS, N.; FILIS, G. Oil prices and stock market correlation: a time-varying approach, *International Journal of Energy and Statistics*, IJES, v. 1, n. 1, p. 17–29, 2013.
- AROURI, M. E. H. Does crude oil move stock markets in europe? a sector investigation, *Economic Modelling*, Elsevier, v. 28, n. 4, p. 1716–1725, 2011.
- BAUR, D. G.; LUCEY, B. M. Is gold a hedge or a safe haven? an analysis of stocks, bonds and gold, *Financial Review*, Wiley Online Library, v. 45, n. 2, p. 217–229, 2010.
- BAUWENS, L.; LAURENT, S.; ROMBOUTS, J. V. Multivariate GARCH models: a survey, *Journal of applied econometrics*, Wiley Online Library, v. 21, n. 1, p. 79–109, 2006.
- BILLIO, M.; CAPORIN, M.; GOBBO, M. Flexible dynamic conditional correlation multivariate GARCH models for asset allocation, *Applied Financial Economics Letters*, Taylor & Francis, v. 2, n. 02, p. 123–130, 2006.
- BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity, *Journal of econometrics*, Elsevier, v. 31, n. 3, p. 307–327, 1986.
- BOLLERSLEV, T. Modelling the coherence in short-run nominal exchange rates: a multivariate generalized arch model. *The review of economics and statistics*, JSTOR, p. 498–505, 1990.
- BOLLERSLEV, T.; ENGLE, R. F.; WOOLDRIDGE, J. M. A capital asset pricing model with time-varying covariances, *Journal of political Economy*, The University of Chicago Press, v. 96, n. 1, p. 116–131, 1988.
- BOURI, E.; BOYRIE, M. E. de; PAVLOVA, I. Volatility transmission from commodity markets to sovereign CDS spreads in emerging and frontier countries, *International Review of Financial Analysis*, Elsevier, v. 49, p. 155–165, 2017.
- BOYRIE, M. E. de; PAVLOVA, I. *Linkages between equity and commodity markets: Are emerging markets different?*, [S.l.: s.n.], 2016.
- BÜYÜKSAHİN, B.; ROBE, M. A. Speculators, commodities and cross-market linkages, *Journal of International Money and Finance*, Elsevier, n. 42, p. 38–70, 2014.

- CAPPIELLO, L.; ENGLE, R. F.; SHEPPARD, K. Asymmetric dynamics in the correlations of global equity and bond returns,*Journal of Financial econometrics*, Oxford University Press, v. 4, n. 4, p. 537–572, 2006.
- CHANG, C.-L.; MCALEER, M.; TANSUCHAT, R. Conditional correlations and volatility spillovers between crude oil and stock index returns,*The North American Journal of Economics and Finance*, Elsevier, v. 25, p. 116–138, 2013.
- CHOI, K.; HAMMOUDEH, S. Volatility behavior of oil, industrial commodity and stock markets in a regime-switching environment,*Energy Policy*, Elsevier, v. 38, n. 8, p. 4388–4399, 2010.
- CHONG, J.; MIFFRE, J. Conditional correlation and volatility in commodity futures and traditional asset markets,*The Journal of Alternative Investments*, v. 12, n. 3, p. 61–75, 2010.
- CRETI, A.; JOËTS, M.; MIGNON, V. On the links between stock and commodity markets' volatility,*Energy Economics*, Elsevier, v. 37, p. 16–28, 2013.
- DEMIRALAY, S.; ULUSOY, V. Links between commodity futures and stock market: Diversification benefits, financialization and financial crises,*Munich Personal RePEc Archive*, MPRA, n. 59727, p. 1–12, 2014.
- DICKEY, D. A.; FULLER, W. A. Distribution of the estimators for autoregressive time series with a unit root,*Journal of the American statistical association*, Taylor & Francis, v. 74, n. 366a, p. 427–431, 1979.
- ENGLE, R. Dynamic conditional correlation: A simple class of multivariate generalized autoregressive conditional heteroskedasticity models,*Journal of Business & Economic Statistics*, Taylor & Francis, v. 20, n. 3, p. 339–350, 2002.
- ENGLE, R. F.; KRONER, K. F. Multivariate simultaneous generalized ARCH,*Econometric theory*, Cambridge University Press, v. 11, n. 1, p. 122–150, 1995.
- ENGLE, R. F.; NG, V. K.; ROTHSCCHILD, M. Asset pricing with a factor-ARCH covariance structure: Empirical estimates for treasury bills,*Journal of Econometrics*, Elsevier, v. 45, n. 1-2, p. 213–237, 1990.
- ERB, C. B.; HARVEY, C. R. The strategic and tactical value of commodity futures,*Financial Analysts Journal*, CFA Institute, v. 62, n. 2, p. 69–97, 2006.
- EWING, B. T.; MALIK, F. Volatility transmission between gold and oil futures under structural breaks,*International Review of Economics and Finance*, v. 25, p. 113–121, 2013.
- FILIS, G.; DEGIANNAKIS, S.; FLOROS, C. Dynamic correlation between stock market and oil prices: The case of oil-importing and oil-exporting countries,*International Review of Financial Analysis*, Elsevier, v. 20, n. 3, p. 152–164, 2011.
- GLOSTEN, L. R.; JAGANNATHAN, R.; RUNKLE, D. E. On the relation between the expected value and the volatility of the nominal excess return on stocks,*The journal of finance*, Wiley Online Library, v. 48, n. 5, p. 1779–1801, 1993.

JARQUE, C. M.; BERA, A. K. Efficient tests for normality, homoscedasticity and serial independence of regression residuals,*Economics letters*, Elsevier, v. 6, n. 3, p. 255–259, 1980.

KAWAKATSU, H. Matrix exponential GARCH,*Journal of Econometrics*, Elsevier, v. 134, n. 1, p. 95–128, 2006.

KRONER, K. F.; NG, V. K. Modeling asymmetric comovements of asset returns,*The review of financial studies*, Oxford University Press, v. 11, n. 4, p. 817–844, 1998.

KRONER, K. F.; SULTAN, J. Time-varying distributions and dynamic hedging with foreign currency futures,*Journal of Financial and Quantitative Analysis*, Cambridge University Press, v. 28, n. 4, p. 535–551, 1993.

LANNE, M.; SAIKKONEN, P. A multivariate generalized orthogonal factor GARCH model,*Journal of Business & Economic Statistics*, Taylor & Francis, v. 25, n. 1, p. 61–75, 2007.

LEVINE, A.; OOI, Y. H.; RICHARDSON, M. Commodities on the long run,*NBER Working Paper*, NBER, n. 22793, p. 1–40, 2016.

LJUNG, G. M.; BOX, G. E. On a measure of lack of fit in time series models,*Biometrika*, Oxford University Press, v. 65, n. 2, p. 297–303, 1978.

MANERA, M.; NICOLINI, M.; VIGNATI, I. Financial speculation in energy and agriculture futures markets: A multivariate GARCH approach,*The Energy Journal*, IAEE, v. 34, n. 3, p. 55–81, 2013.

MARKOWITZ, H. Portfolio selection,*The journal of finance*, Wiley Online Library, v. 7, n. 1, p. 77–91, 1952.

MCALCER, M.; HOTI, S.; CHAN, F. Structure and asymptotic theory for multivariate asymmetric conditional volatility,*Econometric Reviews*, Taylor & Francis, v. 28, n. 5, p. 422–440, 2009.

MENSI, W. et al. Correlations and volatility spillovers across commodity and stock markets: Linking energies, food, and gold,*Economic Modelling*, Elsevier, v. 32, p. 15–22, 2013.

NELSON, D. B. Conditional heteroskedasticity in asset returns: A new approach,*Econometrica: Journal of the Econometric Society*, JSTOR, p. 347–370, 1991.

ÖZTEK, M. F.; ÖCAL, N. Financial crises, financialization of commodity markets and correlation of agricultural commodity index with precious metal index and S&P500,*ERC Working Papers in Economics*, v. 13, n. 02, p. 1–20, 2013.

SADORSKY, P. Oil price shocks and stock market activity,*Energy economics*, Elsevier, v. 21, n. 5, p. 449–469, 1999.

SADORSKY, P. Modeling volatility and correlations between emerging market stock prices and the prices of copper, oil and wheat,*Energy Economics*, v. 43, p. 72–81, 2014.

SCHWARZ, G. et al. Estimating the dimension of a model, *The annals of statistics*, Institute of Mathematical Statistics, v. 6, n. 2, p. 461–464, 1978.

SILVENNOINEN, A.; TERÄSVIRTA, T. *Multivariate autoregressive conditional heteroskedasticity with smooth transitions in conditional correlations*. [S.l.: s.n.], 2005.

SILVENNOINEN, A.; TERÄSVIRTA, T. *Multivariate garch models*. Handbook of financial time series, Springer, p. 201–229, 2009.

TOKIC, D. The 2014 oil bust: Causes and consequences, *Energy Policy*, Elsevier, v. 85, p. 162–169, 2015.

TSE, Y. K.; TSUI, A. K. C. A multivariate generalized autoregressive conditional heteroscedasticity model with time-varying correlations, *Journal of Business & Economic Statistics*, Taylor & Francis, v. 20, n. 3, p. 351–362, 2002.

WEIDE, R. Van der. GO-GARCH: a multivariate generalized orthogonal garch model, *Journal of Applied Econometrics*, Wiley Online Library, v. 17, n. 5, p. 549–564, 2002.

APÊNDICE A - Modelos *GARCH* estimados

S&P500: MA(1)-EGARCH(2,1)

Média condicional:

$$y_{S\&P500,t} = 0,0004 + \varepsilon_{S\&P500,t} - 0,063\varepsilon_{S\&P500,t-1} \quad (10)$$

(0,000) (0,000)

Variância condicional:

$$\begin{aligned} \ln h_{S\&P500,t}^2 = & -0,148 - 0,258\varepsilon_{S\&P500,t-1}^2 + 0,116\varepsilon_{S\&P500,t-2}^2 - \\ & (0,000) \quad (0,000) \quad (0,000) \\ & -0,078 \left(|\varepsilon_{S\&P500,t-1}^2| - E(|\varepsilon_{S\&P500,t-1}^2|) \right) + \\ & (0,011) \\ & +0,193 \left(|\varepsilon_{S\&P500,t-2}^2| - E(|\varepsilon_{S\&P500,t-2}^2|) \right) + 0,985 \ln h_{S\&P500,t-1}^2 \quad (11) \\ & (0,000) \quad (0,000) \end{aligned}$$

S&P-GSCI: GARCH(1,1)

Média condicional:

$$y_{GSCI,t} = \varepsilon_{GSCI,t} \quad (12)$$

Variância condicional:

$$\ln h_{GSCI,t}^2 = 0,038\varepsilon_{GSCI,t-1}^2 + 0,959 \ln h_{GSCI,t-1}^2 \quad (13)$$

(0,000) (0,000)

S&P-GSCI Agriculture: MA(1)-GARCH(1,1)

Média condicional:

$$y_{Agri,t} = \varepsilon_{Agri,t} + 0,046\varepsilon_{Agri,t-1} \quad (14)$$

(0,002)

Variância condicional:

$$\ln h_{Agri,t}^2 = 0,047\varepsilon_{Agri,t-1}^2 + 0,947 \ln h_{Agri,t-1}^2 \quad (15)$$

(0,000) (0,000)

S&P-GSCI Energy: EGARCH(1,1)

Média condicional:

$$y_{Ener.,t} = \varepsilon_{Ener.,t} \quad (16)$$

Variância condicional:

$$\begin{aligned} \ln h_{Ener.,t}^2 = & -0,032 - 0,047 \varepsilon_{Ener.,t-1}^2 + 0,091 \left(|\varepsilon_{Ener.,t-1}^2| - E(|\varepsilon_{Ener.,t-1}^2|) \right) + \\ & (0,000) \quad (0,000) \quad (0,000) \\ & + 0,996 \ln h_{Ener.,t-1}^2 \\ & (0,000) \end{aligned} \quad (17)$$

S&P-GSCI Industrial Metals: MA(1)-GARCH(1,1)

Média condicional:

$$y_{I.Metals,t} = \varepsilon_{I.Metals,t} - 0,055 \varepsilon_{I.Metals,t-1} \quad (18)$$

(0,000)

Variância condicional:

$$\begin{aligned} \ln h_{M.Ind.,t}^2 = & 0,042 \varepsilon_{I.Metals,t-1}^2 + 0,953 \ln h_{I.Metals,t-1}^2 \\ & (0,000) \quad (0,000) \end{aligned} \quad (19)$$

S&P-GSCI Precious Metals: ARMA(0,0)-EGARCH(1,1)

Média condicional:

$$y_{P.Metals,t} = 0,0004 + \varepsilon_{P.Metals,t} \quad (20)$$

(0,000)

Variância condicional:

$$\ln h_{P.Metals,t}^2 = -0,053 + 0,302\varepsilon_{P.Metals,t-1}^2 + 0,094 \left(|\varepsilon_{P.Metals,t-1}^2| - E(|\varepsilon_{P.Metals,t-1}^2|) \right) +$$

(0,000) (0,000) (0,000)

$$+ 0,994 \ln h_{P.Metals,t-1}^2 \quad (21)$$

(0,000)

S&P-GSCI Livestock: AR(1)-EGARCH(1,3)

Média condicional:

$$y_{Live.,t} = 0,056y_{Live.,t-1} + \varepsilon_{Live.,t} \quad (22)$$

Variância condicional:

$$\ln h_{Live.,t}^2 = -0,121 - 0,028\varepsilon_{Live.,t-1}^2 + 0,083 \left(|\varepsilon_{Live.,t-1}^2| - E(|\varepsilon_{Live.,t-1}^2|) \right) +$$

(0,000) (0,000) (0,000)

$$+ 0,999 \ln h_{Live.,t-1}^2 - 0,110 \ln h_{Live.,t-2}^2 + 0,097 \ln h_{Live.,t-3}^2 \quad (23)$$

(0,000) (0,000) (0,000)

DCC-GARCH(1,1)

$$\mathbf{Q}_t = 0,002\bar{\mathbf{Q}} + 0,029\mathbf{v}_{t-1}\mathbf{v}'_{t-1} + 0,969\mathbf{Q}_{t-1} \quad (24)$$

(0,000) (0,000) (0,000)

APÊNDICE B - Tabela com testes de consistência dos modelos estimados

Tabela 7 - Resultados das estatísticas dos testes

Coeficiente	Q(*)	Q ² (*)	ARCH(*)
S&P500	1,307 (0,550)	1,732 (0,898)	0,597 (0,865)
GSCI	1,167 (0,447)	4,711 (0,178)	0,092 (0,989)
Agricultura	1,224 (0,602)	1,941 (0,632)	2,399 (0,390)
Energia	1,487 (0,364)	5,685 (0,107)	0,412 (0,909)
M. Industriais	1,463 (0,458)	8,777 (0,019)	1,668 (0,549)
Pecuária	1,143 (0,652)	14,501 (0,011)	3,919 (0,207)
M. Preciosos	0,200 (0,854)	47,20 (0,000)	3,318 (0,247)

Nota(1): O número de defasagens (*) obedece a seguinte fórmula: $[2(p + q) + (p + q) - 1]$.

Nota(2): Entre parênteses estão os p-valores.

Fonte: O autor, 2017.

APÊNDICE C - Correlações condicionais entre *commodities*

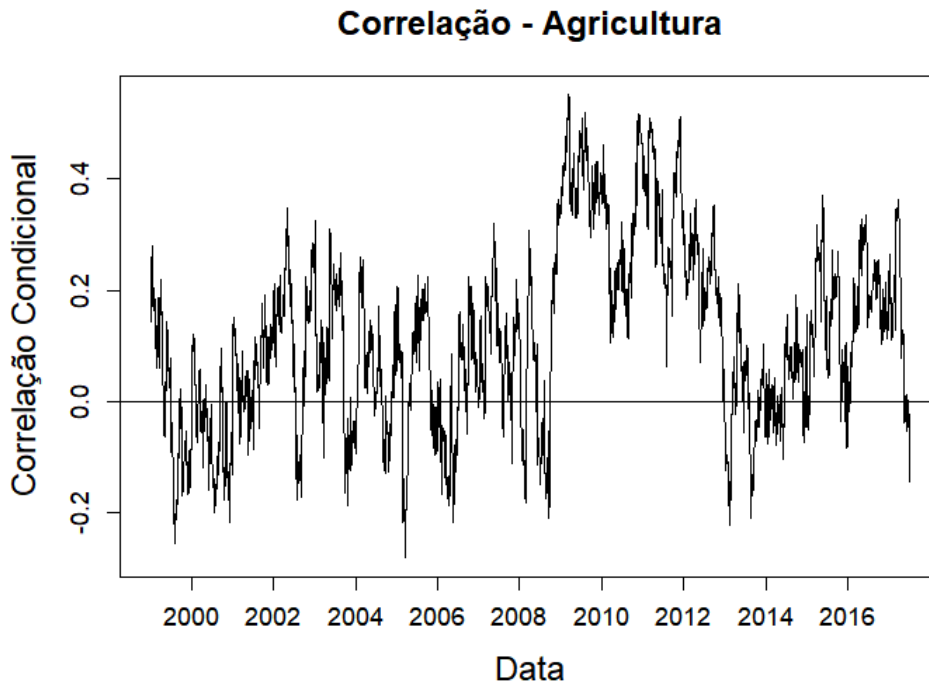
Tabela 8 - Correlações condicionais (apenas *commodities*) - Estatísticas

1999-2017	Média	Desv. Pad.	Mín.	Máx.
Agricultura-Energia	0,233	0,178	-0,197	0,735
Agricultura-M.Industriais	0,215	0,165	-0,122	0,707
Agricultura-Pecuária	0,099	0,149	-0,284	0,595
Energia-M.Industriais	0,277	0,226	-0,346	0,782
Energia-Pecuária	0,107	0,141	-0,252	0,594
M.Preciosos-Agricultura	0,183	0,145	-0,262	0,582
M.Preciosos-Energia	0,244	0,161	-0,257	0,746
M.Preciosos-M.Industriais	0,294	0,205	-0,281	0,662
M.Preciosos-Pecuária	0,037	0,116	-0,352	0,405
Pecuária-M.Industriais	0,108	0,134	-0,270	0,499
Apenas 2008	Média	Desv. Pad.	Mín.	Máx.
Agricultura-Energia	0,498	0,130	0,220	0,735
Agricultura-M.Industriais	0,434	0,141	0,162	0,707
Agricultura-Pecuária	0,225	0,193	-0,114	0,595
Energia-M.Industriais	0,511	0,131	0,197	0,710
Energia-Pecuária	0,228	0,141	-0,011	0,514
M.Preciosos-Agricultura	0,352	0,085	0,144	0,523
M.Preciosos-Energia	0,480	0,072	0,319	0,587
M.Preciosos-M.Industriais	0,438	0,126	0,114	0,604
M.Preciosos-Pecuária	0,112	0,056	-0,064	0,257
Pecuária-M.Industriais	0,155	0,180	-0,103	0,499

Fonte: O autor, 2017.

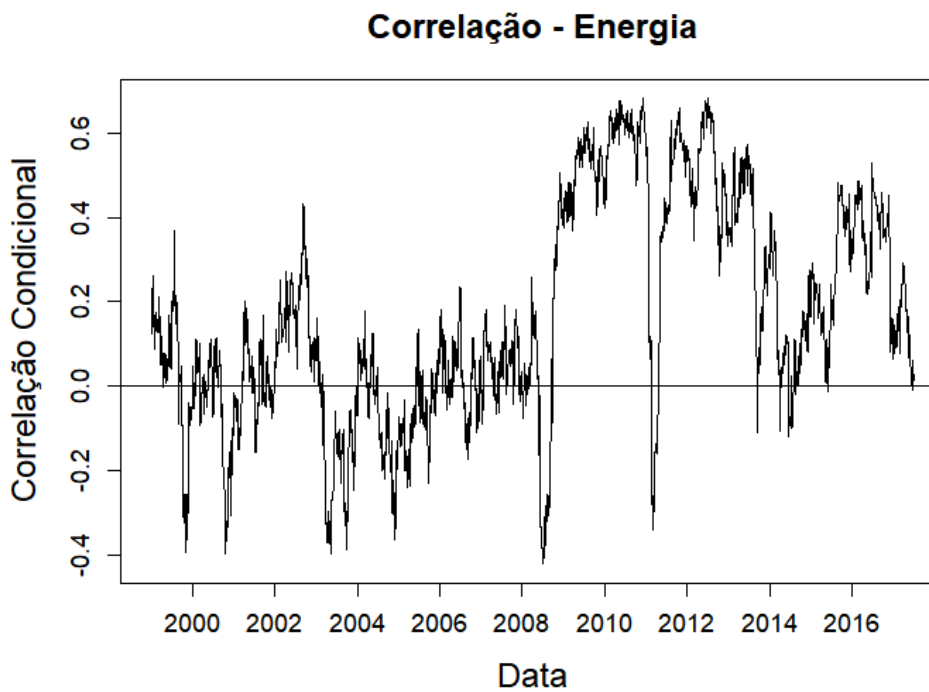
APÊNDICE D - Gráficos das correlações condicionais S&P500 versus *commodities*

Figura 3 - S&P500 versus Agricultura

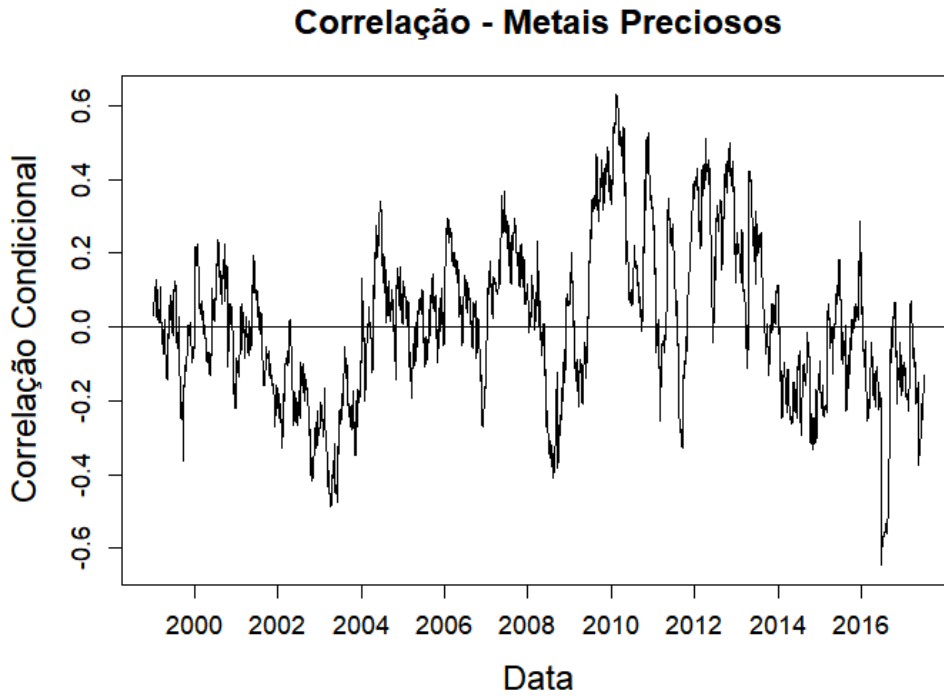


Fonte: O autor, 2017.


Figura 4 - S&P500 versus Energia




Fonte: O autor, 2017.

Figura 5 - S&P500 *versus* Metais Preciosos

Fonte: O autor, 2017.

Figura 6 - S&P500 *versus* Pecuária

Fonte: O autor, 2017.

Figura 7 - S&P500 *versus* Metais Industriais

Fonte: O autor, 2017.