

**INCERTEZA POLÍTICA E ECONÔMICA E VOLATILIDADE DOS MERCADOS
ACIONÁRIOS DOS PAÍSES DO BRICS: UMA APLICAÇÃO DA MODELAGEM GARCH-
MIDAS**

ALINE MOURA COSTA DA SILVA
UNIVERSIDADE FEDERAL FLUMINENSE (UFF)

ANNA PAOLA FERNANDES FREIRE
UNIVERSIDADE FEDERAL DA PARAÍBA (UFPB)

OTAVIO RIBEIRO DE MEDEIROS
UNIVERSIDADE DE BRASÍLIA (UNB)

INCERTEZA POLÍTICA E ECONÔMICA E VOLATILIDADE DOS MERCADOS ACIONÁRIOS DOS PAÍSES DO BRICS: UMA APLICAÇÃO DA MODELAGEM GARCH-MIDAS

Introdução

A medição da volatilidade dos mercados financeiros é um desafio primário da gestão de risco. Sua mensuração e projeção permitem que os agentes econômicos (investidores, acadêmicos ou agentes públicos) tomem decisões mais robustas sobre a alocação de ativos, o gerenciamento de risco, a formação da estratégia de *hedge*, a negociação de derivativos e a otimização de portfólio (Asgharian, Hou & Javed, 2013; Zheng, Quiao, Takaishi, Stanleu & Li, 2014; Mo, Gupta, Li & Singh, 2018; Gaetano, 2018).

Não é surpresa que uma extensa pesquisa sobre os efeitos macroeconômicos e a volatilidade seja encontrada na literatura nacional e internacional (Asgharian, Hou & Javed, 2013). Estimativas iniciais, principalmente após o desenvolvimento de modelos de Heteroscedasticidade Condicional Autoregressiva (ARCH), desenvolvido por Engle (1982), e de Heteroscedasticidade Condicional Autorregressiva Generalizada (GARCH), introduzido por Bollerslev (1986), já relacionavam a volatilidade com componentes macroeconômicos (Perez-Quiros & Timmermann, 2000; Brandt & Kang, 2004), permitindo, assim, a análise da volatilidade dos mercados acionários.

Muito embora essa relação tenha proporcionado avanços importantes, tais estudos limitavam-se às análises de determinadas variáveis macroeconômicas com um intervalo de frequência mais extenso, muitas vezes pela necessidade de as variáveis estarem em uma mesma frequência na equação de regressão aplicada. Contudo, a partir da modelagem conhecida como *Mixed Data Sampling* (MIDAS), introduzida por Ghysels, Santa-Clara e Valkanov (2004, 2005), foi possível fazer com que dados com distintas frequências fossem relacionados em uma mesma equação de regressão, o que, conseqüentemente, minimiza a perda informacional existente quando as variáveis de alta frequência são transformadas em variáveis de frequências menores, haja vista que para a estimação dos modelos convencionais de regressão, é preciso que os dados estejam amostrados em uma mesma frequência (Ghysels, Santa-Clara & Valkanov, 2004; Ghysels, Sinko & Valkanov, 2007; Andreou, Ghysels & Kourtellos, 2010, 2013; Chambers, 2016).

Entre as derivações do modelo MIDAS, encontra-se o modelo GARCH-MIDAS, iniciado por Engle, Ghysels e Sohn (2013). A literatura internacional na área de economia e finanças tem mostrado estudos nessa linha de pesquisa, ao aplicar tal modelo para analisar a volatilidade dos mercados acionários ao longo do tempo (Engle, Ghysels & Sohn, 2013; Yin & Zhou, 2016; Pan, Wang, Wu & Yin, 2017; Conrad, Custovic & Ghysels, 2018). Uma vez que o modelo GARCH-MIDAS permite vincular, por exemplo, as observações diárias dos retornos acionários com variáveis macroeconômicas, amostradas em frequências mais baixas, a fim de examinar diretamente o impacto dessas variáveis sobre a volatilidade das ações, a repercussão desse impacto e as correlações irão reportar o efeito de condições macroeconômicas mais amplas na condução da integração do mercado financeiro (Virk & Javed, 2017).

De acordo com Engle, Ghysels e Sohn (2013), resumidamente, o modelo GARCH-MIDAS possibilita a extração de dois componentes da volatilidade, um pertencente às oscilações de curto prazo, e o outro relacionado às de longo prazo. É válido ainda ressaltar que esses autores entendem que os modelos de componentes de longo prazo, impulsionados por variáveis macroeconômicas, estão no mesmo patamar em

termos de projeção fora da amostra, além de superarem as estatísticas de modelos de séries temporais, os quais a perda de eficiência devido à estimação em múltiplos passos é reduzida. Ademais, pode-se considerar que a macroeconomia está evoluindo ao modelar o componente de baixa frequência da volatilidade com o modelo GARCH-MIDAS, que pode ser usado para qualquer série sem exigir especificação da estrutura econômica. Um componente de longo prazo pode descrever os recursos de memória longa do processo de volatilidade (Engle & Rangel, 2008).

Nesse contexto, uma vez que os países emergentes têm como uma das principais características a alta volatilidade no retorno de suas ações, torna-se necessária a investigação desse fator nesses mercados (Chen, Firth & Rui, 2001; Akinkugbe, 2005; Brzezczynski, Gajdka & Kutan, 2015; Mo, Gupta, Li & Singh, 2018), já que há crescente interesse de investidores de países desenvolvidos nesses. Segundo Kedia, Rhew, Gaffney e Clampit (2015), as empresas multinacionais de mercados em desenvolvimento são grandes *players* no mercado mundial, representando uma parte crescente do investimento estrangeiro direto. Em adição, Brzezczynski, Gajdka e Kutan (2015) e Ghysels, Plazzi e Valkanov (2016) afirmam que, ao longo dos últimos vinte anos, os mercados acionários de países emergentes têm crescido de forma significativa, em números e volume de negociação.

Entre os países emergentes destacam-se os países inseridos no BRICS (Brasil, Rússia, Índia, China e África do Sul), os quais são reconhecidos como as economias mais desenvolvidas entre os mercados emergentes. Todos esses são países em desenvolvimento ou recém-industrializados, além de serem considerados grandes economias, demonstrando rápido crescimento e forte influência nos negócios regionais e globais. Gaetano (2018) afirma que tais países representam 13,24% do poder de voto do Banco Mundial e 14,91% das cotas do Fundo Monetário Internacional (FMI). De acordo com o FMI, os países do BRICS geraram 22,53% do PIB mundial em 2015 e contribuíram com mais de 50% do crescimento econômico mundial nos últimos 10 anos. Sua resistência às crises financeiras, ou seja, a persistência da volatilidade, juntamente com uma maior integração financeira regional, fez o grupo de países do BRICS um interessante estudo de caso que evidencia a inter-relação entre a estabilidade financeira e o crescimento econômico (Morales & Gassie-Falzone, 2011).

Muito embora os países pertencentes ao BRICS tenham características semelhantes, suas ações políticas nem sempre coincidem com o ritmo internacional ditado, principalmente, pelos países desenvolvidos. O Brasil, por exemplo, desde o segundo trimestre de 2014, de acordo com a Fundação Getúlio Vargas (FGV), em seu Relatório de 2015, sofre um período de recessão econômica e instabilidade política, iniciadas por evidências de corrupção no país e, em especial, na Petrobrás, apontadas pela operação “Lava-Jato”. Tais evidências de corrupção na Petrobrás provocaram quedas nos preços de diversas empresas e, também, no índice da bolsa de valores de São Paulo (Ibovespa), segundo a Revista Exame (março/2016). Já, na Rússia, o presidente russo anunciou a necessidade de reformar as instituições de *Bretton Woods*, sendo a sua motivação apenas mais uma proteção aos parceiros comerciais daquele país, do que a reforma das instituições financeiras do próprio país. Na China, o governo decidiu não depender tanto das exportações e desenvolver o mercado interno (Morales & Gassie-Falzone, 2011). Por fim, a economia da Índia, que se destaca por possuir o maior comércio de *commodities* juntamente com o mercado Chinês, entre os países emergentes, leva em consideração o impacto das condições macroeconômicas internacionais sobre a volatilidade dessas *commodities*, passando por formulações e decisões políticas (Mo et al., 2018). Tais medidas sugerem que a incerteza política e econômica afeta o

investimento corporativo por meio de decisões financeiras e canais de oferta e demanda (Gulen & Ion, 2016).

Diante desse contexto, o presente artigo busca responder a seguinte questão de pesquisa: **Como a incerteza política e econômica influencia a volatilidade dos mercados acionários dos países representantes do BRICS, por meio da modelagem GARCH-MIDAS?**

O objetivo deste artigo, inicialmente, foi examinar o efeito de duas variáveis, o índice de incerteza política e econômica (EPU) e a taxa de inflação (CPI), *proxy* de incerteza econômica, individualmente, sobre a volatilidade do mercado acionário dos países pertencentes ao BRICS, com a aplicação do modelo GARCH-MIDAS. Além disso, o artigo também se propôs a avaliar a projeção dessa volatilidade com base naquelas variáveis. Contudo, é válido ressaltar que, especificamente, para a África do Sul as análises não foram realizadas devido à falta de dados do índice EPU para esse país, constatando assim, uma limitação desta pesquisa.

O artigo está dividido em quatro seções. Estimativas com o GARCH-MIDAS, principalmente, foram revisados na primeira seção, a fim de serem apresentadas algumas possibilidades de aplicação de tal modelo. O modelo GARCH-MIDAS está explicado na segunda seção. As análises do impacto das variáveis EPU e CPI, sobre a volatilidade dos mercados acionários dos países pertencentes ao BRIC, são demonstradas na terceira seção. E, finalmente, as considerações finais apresentadas na última seção complementam a análise proposta nesta pesquisa.

2. Revisão da literatura

Asgharian, Hou e Javed (2013) analisaram se as informações contidas nas variáveis macroeconômicas (inflação inesperada, prêmio de longo prazo, crescimento da renda do trabalho *per capita*, prêmio de inadimplência, taxa de desemprego, taxa de juros de curto prazo, consumo *per capita*), via abordagem de componente principal, poderiam ajudar a prever os componentes de longo prazo associados à variação do retorno acionário, por meio do índice diário do preço dos EUA, no período de janeiro de 1991 a junho de 2008. Os resultados indicaram que o modelo GARCH-MIDAS constituiu uma melhor previsão do que a apresentada pelo modelo GARCH tradicional. Além disso, a inclusão de variáveis macroeconômicas com baixa frequência (mensal) aumentou significativamente a capacidade de previsão do modelo para a variância a longo prazo (mensal), bem como a capacidade de previsão do modelo para as variâncias de alta frequência (diárias).

A aplicação do modelo GARCH-MIDAS também pode ser vista em Yin e Zhou (2016), ao examinarem o papel da especulação e dos fundamentos econômicos no petróleo dos EUA. Para tanto, foram empregados dados diários para o período de janeiro de 1988 até o final do ano de 2015. Seus resultados demonstraram que o choque da demanda global é o único fator que aumenta a volatilidade do petróleo no longo ou curto prazos, durante todo o período da amostra.

Um estudo também pertinente foi desenvolvido por Yu, Fang, Du e Yan (2017) que, apesar de não terem aplicado o GARCH-MIDAS, mas sim o *Dynamic Conditional Correlation - Mixed Data Sampling* (DCC-MIDAS), com uma visão setorial baseada nos índices do setor nível 1 da *Global Industry Classification Standard* (GICS), propuseram estimar, de janeiro de 1993 a dezembro de 2015, o beta de longo prazo das indústrias de 10 setores dos EUA, considerando o seu índice EPU, com a justificativa de que os portfólios industriais são ativos básicos populares em muitos modelos de alocação de ativos, além de o beta da indústria ser uma ferramenta importante para a prática de gerenciamento de risco e para o orçamento de capital. Com isso, os resultados indicaram

que o índice EPU impulsiona significativamente o beta do setor, em média, e o efeito de direção muda substancialmente de acordo com a turbulência do mercado. O beta da indústria impulsionado pelo índice EPU é provavelmente um dos principais indicadores de turbulência quando é alto.

Mo et al. (2018) investigaram os mercados emergentes de *commodities* da China e da Índia, por meio de variáveis macroeconômicas, nacionais e internacionais, que avaliam o ambiente econômico, a política monetária e a informação do mercado financeiro. Para determinar o impacto das variáveis macroeconômicas na volatilidade dos preços das *commodities* selecionadas, os autores empregaram o modelo GARCH-MIDAS. Os resultados sobre o mercado chinês evidenciaram que tanto as variáveis macroeconômicas domésticas, quanto as internacionais, têm fraco impacto econômico sobre a volatilidade dos mercados futuros de *commodities*. Por outro lado, as incertezas das variáveis macroeconômicas, tanto domésticas quanto internacionais, são determinantes importantes dessas volatilidades. Já, para o mercado indiano, os resultados mostraram que tanto no mercado doméstico, quanto no internacional, a informação contida na volatilidade das variáveis macroeconômicas tem um impacto significativo sobre a volatilidade dos mercados futuros de *commodities*.

Fang, Yu e Xiao (2018) aplicaram a modelagem GARCH-MIDAS para analisar, especificamente, o mercado de ouro dos EUA, uma vez que, segundo os autores, tal mercado atraiu recentemente uma atenção significativa por parte dos investidores, além do fato de que a volatilidade do ouro está intimamente relacionada com a macroeconomia. A partir das variáveis utilizadas, tais como, EPU, taxa de inflação, novas encomendas de bens de consumo e materiais, crescimento do emprego, confiança do consumidor, crescimento da produção industrial, habitação e crescimento da oferta de moeda (M1), a análise de componentes principais foi usada para capturar as informações sobre diferentes variáveis macroeconômicas, a fim de verificar se melhoram o desempenho da previsão. Os resultados indicaram um impacto significativo das variáveis macroeconômicas sobre a volatilidade do mercado de ouro durante e após a turbulência econômica, destacando que deve ser dada mais atenção para as variáveis taxa de emprego, taxa de inflação e índice de confiança, devido à sua influência significativa na melhoria do desempenho de projeção para a volatilidade no mercado futuro de ouro.

Ainda sobre o mercado americano, Amendola, Candila e Gallo (2018) investigaram por meio do modelo GARCH-MIDAS, os possíveis impactos macroeconômicos (positivos/negativos) na volatilidade do mercado financeiro. Nesse caso, uma simulação de Monte Carlo foi aplicada, garantindo boas propriedades do estimador com tamanhos de amostra realistas, segundo os autores. Para tal, utilizou-se a volatilidade diária do índice S&P500 com a produção industrial mensal dos EUA e o índice de atividade nacional como determinantes adicionais. Os resultados revelaram que o modelo GARCH-MIDAS proposto não só superou estatisticamente os modelos GARCH e GJR-GARCH, mas demonstrou ganhos significativos de utilidade de média-variância de um investidor sob diferentes parâmetros de aversão ao risco.

3. Metodologia

3.1 Amostra

A amostra contemplou dados diários dos índices das Bolsas dos países representantes do BRIC: Brasil (IBOVESPA), Rússia (IMOEX), Índia (NIFTY100) e China (SHANGHAI), além dos dados mensais dos índices EPU e da taxa de inflação (CPI) de cada país analisado, para o período de dezembro de 2005 a agosto de 2018. O período iniciado em 2005 justifica-se por ser aquele em que todos os países apresentavam os dados necessários para a avaliação. Não foi possível analisar a África do Sul e,

portando o BRICS, pois até o momento da consecução deste artigo, o índice EPU para esse país não havia sido divulgado.

Os dados diários reais dos índices das Bolsas dos países analisados foram coletados da base de dados *Reuters* e seus valores foram transformados em retornos. O índice EPU foi coletado do *site* da Economic Policy Uncertainty e a taxa de inflação, pelo *site* da Organização para a Cooperação e Desenvolvimento Econômico (OECD).

3.2 Modelo GARCH-MIDAS

A modelagem GARCH-MIDAS permite extrair dois componentes da volatilidade: (1) referente às oscilações de curto prazo; e (2) relativo às oscilações de longo prazo. Assim, tal modelagem utiliza um processo GARCH de reversão à média diária da unidade e , também, um polinômio MIDAS, que se aplica às variáveis macroeconômicas ou financeiras cujas frequências podem ser mensais, trimestrais, semestrais ou outras (Engle, Ghysels & Sohn, 2013). Cabe ressaltar que o fato de as séries macroeconômicas estarem em uma frequência diferente não é uma limitação, devido às propriedades da regressão MIDAS.

Isso porque, conforme supramencionado, o modelo MIDAS permite que dados amostrados em diferentes frequências sejam relacionados em uma mesma equação de regressão, amenizando, por conseguinte, a perda de informação existente quando da transformação dessas, tendo em vista que para a estimação dos modelos convencionais de regressão, é necessário que os dados estejam amostrados em uma mesma frequência (Ghysels, Santa-Clara & Valkanov, 2004; Ghysels, Sinko & Valkanov, 2007; Andreou, Ghysels & Kourtellis, 2010, 2013; Chambers, 2016).

A disponibilidade de dados amostrais a uma frequência diferente sempre é um dilema para um pesquisador que trabalha com dados de séries temporais. Por um lado, as variáveis que estão disponíveis em alta frequência contêm informação potencialmente valiosa. Por outro lado, o pesquisador não pode usar diretamente essa informação de alta frequência caso algumas das variáveis estejam disponíveis em uma frequência menor, visto que a maioria das regressões de séries temporais envolve dados amostrais no mesmo intervalo. A solução comum nesses casos é “pré-filtrar” os dados para que as variáveis do lado esquerdo e do lado direito estejam disponíveis com a mesma frequência. Nesse processo, uma grande quantidade de informação potencialmente útil pode ser descartada, tornando assim difícil detectar a relação entre as variáveis (Ghysels, Sinko & Valkanov, 2007, p. 54 - **tradução nossa**).

Ghysels, Santa-Clara e Valkanov (2004) afirmam que a regressão MIDAS, com uma variável explicativa, pode ser definida conforme a Equação 1.

$$y_t = \beta_0 + \beta_1 B(L^{1/m}; \theta) X_t^{(m)} + \varepsilon_t \quad (1)$$

onde, $t = 1, 2, 3, \dots, T$;

$B(L^{1/m}; \theta) = \sum_{k=0}^{k^{max}} B(k; \theta) L^{k/m}$ é um polinômio de extensão k^{max} no operador de defasagem $L^{1/m}$. Ou seja, é um polinômio de grau K , em que K é o número de defasagens de $X_t^{(m)}$ que impactam a estimação de y_t ;

$$L^{k/m} X_t^{(m)} = X_{t-k/m}^{(m)};$$

$B(k; \theta)$ refere-se à uma função parcimoniosa de pesos, em que os coeficientes de defasagem em $B(k; \theta)$, correspondentes ao operador de defasagem $L^{k/m}$, são parametrizados por meio de uma função de vetor de parâmetros θ de pequena dimensão; L é o operador de defasagem;

θ é o vetor de parâmetros dessa função;
 m é o número de vezes que a variável de alta frequência se repete em cada período t ;
 $X_t^{(m)}$ representa a variável independente, em que a frequência é maior do que a da variável dependente, apresentando m observações para t ; e
 β_0, β_1 e θ são os parâmetros, estimados por mínimos quadrados não lineares.

Uma das principais características do MIDAS é a parametrização dos coeficientes defasados de $B(k)$ de forma parcimoniosa, identificada por meio de um dos critérios informacionais *Akaike*, *Schwarz* ou *Hannan-Quinn*. Entre as especificações de polinômios da regressão MIDAS, há em particular as seguintes parametrizações: (1) função de defasagens de *Almon*; (2) função de defasagens exponencial de *Almon*; (3) função polinomial Beta; e (4) função *step*¹ (Ghysels, Sinko & Valkanov, 2007).

A partir da modelagem MIDAS, foram realizados diversos estudos e avanços econométricos, entre eles o modelo desenvolvido por Engle, Ghysels e Sohn (2013) que, revisando a relação entre a volatilidade do mercado de ações e a atividade macroeconômica, introduziram na literatura o modelo GARCH-MIDAS. Tal modelo baseia-se no pressuposto de que os retornos inesperados podem ser descritos conforme a Equação 2.

$$r_{i,t} - E_{i-1,t}(r_{i,t}) = \sqrt{\tau_t \cdot g_{i,t}} \varepsilon_{i,t} \quad (2)$$

onde, $r_{i,t}$ é o retorno registrado no dia i durante o período t ; $E_{i-1,t}(\cdot)$ é a expectativa condicional dadas as informações até o momento $(i-1)$; $g_{i,t}$ é o componente de curto prazo que explica as flutuações diárias; e τ_t é o componente de longo prazo (componente secular).

Girardin e Joyeux (2013) informam que é assumido que $E_{i-1,t}(r_{i,t}) = \mu$, pois, para os dados diários, há pouca previsibilidade nos retornos. Logo, é possível reescrever a Equação 2 como:

$$r_{i,t} = \mu + \sqrt{\tau_t \cdot g_{i,t}} \varepsilon_{i,t} \quad (3)$$

onde, $\varepsilon_{i,t} | \Phi_{i-1,t} \sim N(0,1)$; e $\Phi_{i-1,t}$ é a informação configurada no dia $(i-1)$ do período t .

Diante do exposto, a Equação 3 expressa a variância como um componente de curto prazo definido por $g_{i,t}$ e um componente de longo prazo definido por τ_t , sendo que a dinâmica da variância condicional do componente de curto prazo é um processo GARCH (1,1), de acordo com a Equação 4.

$$g_{i,t} = (1 - \alpha - \beta) + \alpha \frac{(r_{i-1,t} - \mu)^2}{\tau_t} + \beta g_{i-1,t} \quad (4)$$

Engle, Ghysels e Sohn (2013) exibem algumas especificações na modelagem GARCH-MIDAS, entre elas, uma baseada na volatilidade realizada, em que τ é fixado no período t (janela fixa para o filtro MIDAS), e outra com base na incorporação direta de

¹ Para maiores detalhes em relação às parametrizações dos coeficientes defasados no modelo MIDAS, ver Ghysels, Santa-Clara e Valkanov (2007).

séries temporais macroeconômicas, individualmente. Tais especificações são empregadas nesta pesquisa.

De tal modo, τ_t , definido como a volatilidade realizada suavizada no contexto da regressão MIDAS, em que τ é fixado no período t , pode ser representado conforme a Equação 5.

$$\tau_t = m + \theta \sum_{k=1}^K \varphi_k(w_1, w_2) RV_{t-k} \quad (5)$$

onde, $RV_t = \sum_{i=1}^{N'} r_{i,t}^2$ é a volatilidade realizada pela janela fixa (por exemplo, quando $N' = 30$, tem-se uma volatilidade realizada mensalmente; quando $N' = 90$, tem-se uma volatilidade percebida trimestralmente); m e θ são o intercepto e a inclinação, respectivamente, do filtro MIDAS da janela fixa; K é o número de períodos sobre os quais a volatilidade foi suavizada; $\varphi_k(\omega_1, \omega_2)$ é a função de ponderação de defasagens, utilizando tanto as estruturas de atraso ponderadas pelo Beta, quanto ponderadas exponencialmente.

$$\varphi_k(w_1, w_2) = \frac{(k/K)^{w_1-1} (1-k/K)^{w_2-1}}{\sum_{j=1}^k (j/K)^{w_1-1} (1-j/K)^{w_2-1}}, \text{Beta}$$

$$\varphi_k(w) = \frac{w^k}{\sum_{j=1}^K w^j}, 0 < w < 1, \text{Exponencial} \quad (6)$$

onde, os pesos somam até 1.

A função de ponderação ou função de suavização apresentada na Equação 6 é a estrutura de atraso “Beta” ou a “ponderação exponencial”, comumente utilizada. O atraso beta, baseado na função beta, é muito flexível por acomodar várias estruturas de defasagens (Engle, Ghysels & Sohn, 2013).

Assim, as Equações 3-6 formam o modelo GARCH-MIDAS para a variância condicional com janela fixa para o filtro MIDAS. É importante salientar que as especificações baseadas na incorporação direta de séries temporais macroeconômicas seguem a mesma lógica da janela fixa, segundo Engle, Ghysels e Sohn (2013), conforme demonstrado abaixo.

$$\tau_t = m_l + \theta_l \sum_{k=1}^{K_l} \varphi_k(w_{1,l}, w_{2,l}) X_{l,t-k}^{mv} \quad (7)$$

onde, l é o nível e mv é uma variável macro.

Com base no exposto, inicialmente o modelo GARCH-MIDAS é baseado apenas na volatilidade realizada e, em seguida, são inseridas as variáveis macroeconômicas nesse modelo, a fim de identificar se tais variáveis melhoram o poder explicativo do modelo, assim como a projeção da volatilidade dos retornos acionários.

Por fim, cabe informar que, de acordo com Engle, Ghysels e Sohn (2013) e Conrad, Custovic e Ghysels (2018), os modelos GARCH-MIDAS são estimados por quase-máxima verossimilhança e constroem erros-padrões consistentes à heteroscedasticidade e autocorrelação (HAC).

4. Análise dos resultados

Antes de serem extraídas as volatilidades das séries dos retornos dos mercados acionários dos países aqui analisados, foi realizado o teste *Augemented Dickey-Fuller* (ADF), para todas as séries das variáveis, tanto dos retornos dos índices da Bolsa de cada país, como dos seus respectivos índices EPU e CPI, com o intuito de verificar se tais séries são estacionárias. Os resultados de tal teste identificaram que as séries analisadas apresentam comportamento estacionário, ou seja, são $I(0)$.

Em seguida, as volatilidades das séries diárias dos retornos dos mercados acionários dos países representantes do BRIC foram extraídas. Os gráficos que demonstram a volatilidade condicional e o seu componente de longo prazo (volatilidade secular), para o índice representativo do mercado acionário de cada país, são apresentados abaixo, em que a linha preta representa a volatilidade secular e a linha pontilhada cinza, a volatilidade total.

Gráfico 1: Volatilidade condicional e o seu componente de longo prazo (volatilidade secular) para o Brasil

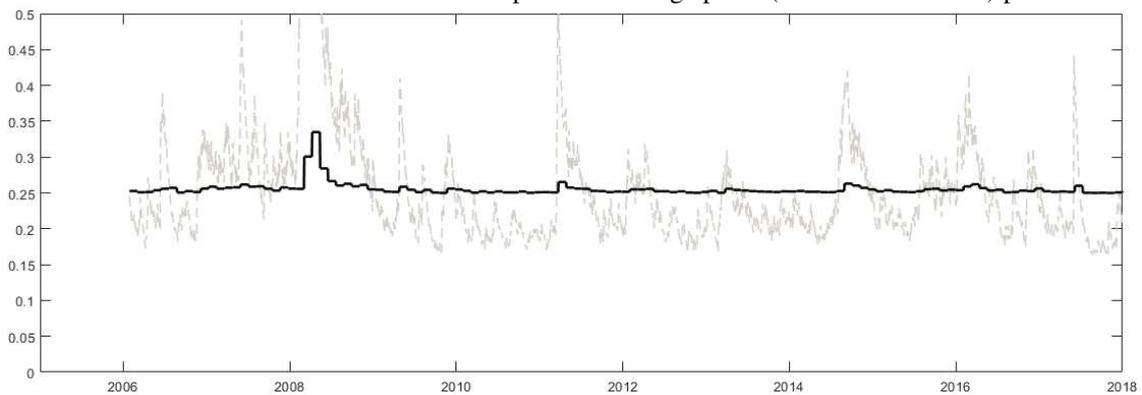


Gráfico 2: Volatilidade condicional e o seu componente de longo prazo (volatilidade secular) para Rússia

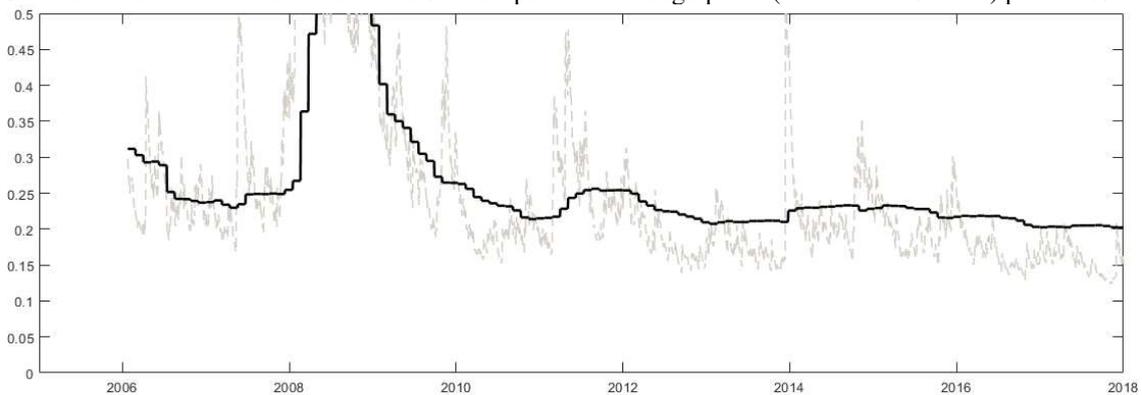


Gráfico 3: Volatilidade condicional e o seu componente de longo prazo (volatilidade secular) para Índia

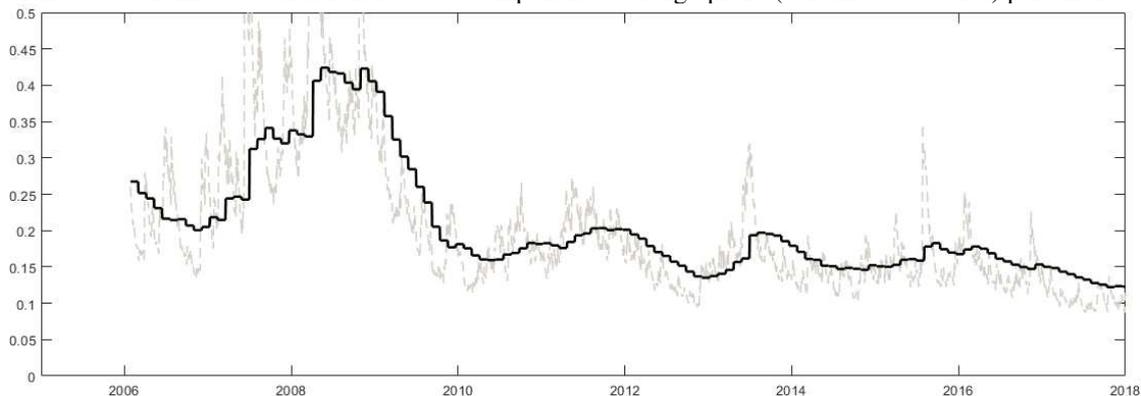
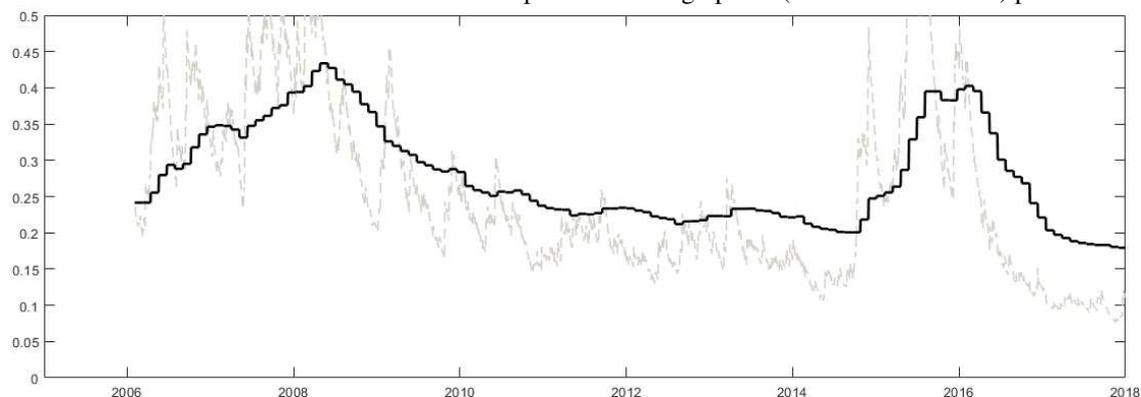


Gráfico 4: Volatilidade condicional e o seu componente de longo prazo (volatilidade secular) para China



De modo geral, com exceção do Brasil, a volatilidade total não seguiu o mesmo comportamento da volatilidade condicional, como verificado nos demais países. Outro ponto de destaque nos 4 gráficos, foi a impacto da crise dos *subprimes* em 2008, na volatilidade da série de cada país, mostrando que o período de recessão nos EUA afetou os países emergentes.

A China (Gráfico 4) ainda apresentou outro pico de volatilidade em seu índice financeiro, em torno de 2016. Uma possível explicação pode estar relacionada com as divulgações de constantes quedas nos dados da indústria chinesa, abaixo das expectativas dos investidores (EXAME, 2016).

Após extrair os dois componentes da volatilidade, de curto e longo prazos, são estimados os modelos GARCH-MIDAS, um baseado na volatilidade realizada e outros dois com a inclusão das variáveis macro, EPU e CPI, individualmente, para cada país aqui analisado. Os resultados dessas estimações estão apresentados na Tabela 1.

Tabela 1 – Resultados das estimações dos modelos GARCH-MIDAS

GARCH-MIDAS		RV			EPU			CPI		
B R A S I L	Tam. da amostra	3.155			3.155			3.155		
	Amostra ajustada	2.979			3.089			3.023		
	Log Verossim.	8227,68			8516,39			8328,3		
	Crit.Inf.Akaike	-16443,4			-17020,8			-16644,6		
	Crit.Inf.Bayesiano	-16407			-16984,4			-16698,3		
		Variáveis	Coef.	Estat.-t	P-valor	Coef.	Estat.-t	P-valor	Coef.	Estat.-t
	μ	0,0005	1,8784	0,0603*	0,0005	1,9927	0,0463*	0,0005	1,9444	0,0518*
	α	0,0777	9,1833	0,0000***	0,0733	10,0680	0,0000***	0,0504	9,0529	0,0000***
	β	0,8832	61,8880	0,0000***	0,9018	93,4860	0,0000***	0,9008	82,8550	0,0000***
	θ	0,1167	5,7379	0,0000***	0,0000	3,2188	0,0013***	0,0000	2,1990	0,0279**
	w	1,0077	27,8640	0,0000***	1,9483	0,5596	0,5757	5,0000	0,2772	0,7816
	m	0,0131	11,7120	0,0000***	0,0002	8,4971	0,0000***	0,0002	6,3794	0,0000***
R Ú S S I A	Tam. da amostra	3.193			3.193			3.193		
	Amostra ajustada	2.973			3.149			3.105		
	Log Verossim.	8388,08			8785,33			8640,87		
	Crit.Inf.Akaike	-16764,2			-17558,7			-17269,7		
	Crit.Inf.Bayesiano	-16727,7			-17522,3			-17233,3		
		Variáveis	Coef.	Estat.-t	P-valor	Coef.	Estat.-t	P-valor	Coef.	Estat.-t
	μ	0,0006	2,5677	0,0102**	0,0006	2,7154	0,0066***	0,0005	1,8793	0,0602*
	α	0,0881	12,2260	0,0000***	0,0953	14,6090	0,0000***	0,0504	14,8030	0,0000***
	β	0,8712	77,1650	0,0000***	0,8917	132,3800	0,0000***	0,9008	132,3800	0,0000***
	θ	0,1266	12,1770	0,0000***	0,0000	1,5568	0,1195	0,0000	9,6772	0,0000***
	w	1,0983	2,9588	0,0031***	5,1483	0,0000	1,0000	5,0000	0,4772	0,6332
	m	0,0118	19,6320	0,0000***	0,0004	4,6875	0,0000***	0,0001	11,9050	0,0000***
Í N D I A	Tam. da amostra	3.163			3.163			3.163		
	Amostra ajustada	2.943			2.239			2.899		
	Log Verossim.	9025,52			7302,33			8823,05		
	Crit.Inf.Akaike	-18039			-14592,7			-17634,1		
	Crit.Inf.Bayesiano	-18002,7			-14556,3			-17597,8		
		Variáveis	Coef.	Estat.-t	P-valor	Coef.	Estat.-t	P-valor	Coef.	Estat.-t
	μ	0,0007	4,1232	0,0000***	0,0007	3,7494	0,0002***	0,0006	3,0512	0,0023***
	α	0,0914	11,0810	0,0000***	0,0592	6,7129	0,0000***	0,0504	12,4030	0,0000***
	β	0,8679	63,0310	0,0000***	0,9215	75,1290	0,0000***	0,9008	120,7600	0,0000***
	θ	0,1828	20,7970	0,0000***	0,0000	3,3853	0,0007***	0,0000	7,0723	0,0000***
	w	1,7396	4,0077	0,0001***	1,0458	3,7365	0,0002***	5,0000	1,7506	0,0800*
	m	0,0059	7,6110	0,0000***	0,0000	-0,0422	0,9663	0,0000	2,6649	0,0077***
C H I N A	Tam. da amostra	3.105			3.105			3.105		
	Amostra ajustada	2.885			3.039			2.379		
	Log Verossim.	8216,43			5776,76			7010,27		
	Crit.Inf.Akaike	-16420,9			-11541,5			-14008,5		
	Crit.Inf.Bayesiano	-16384,6			-11505,3			-13972,3		
		Variáveis	Coef.	Estat.-t	P-valor	Coef.	Estat.-t	P-valor	Coef.	Estat.-t
	μ	0,0002	0,8757	0,3812	0,0003	0,2420	0,8088	0,0003	1,1485	0,2508
	α	0,0536	12,2360	0,0000***	0,0504	0,6798	0,4967	0,0502	10,6580	0,0000***
	β	0,9403	165,5400	0,0000***	0,9008	7,2926	0,0000***	0,9002	108,5400	0,0000***
	θ	0,1801	7,5365	0,0000***	0,0000	1,8358	0,0664*	0,0000	1,6030	0,1089
	w	1,0800	4,1422	0,0000***	5,0000	1,1652	0,2439	4,9993	1,0551	0,2914
	m	0,0104	4,5012	0,0000***	0,0092	1,8423	0,0654*	0,0001	10,2010	0,0000***

Fonte: Elaboração própria com base nos resultados do *MatlabR2018a*.

***, **, *; significância de 1%, 5% e 10%, respectivamente.

Com base nos resultados da Tabela 1, ao analisar os coeficientes α e β de todas as estimações, é possível verificar que, apesar de as somas desses coeficientes mostrarem-se elevadas, sugerindo um alto grau de persistência, as séries dos retornos dos mercados podem ser modeladas por um processo GARCH (1,1) estacionário, tendo em vista que a condição de estacionariedade da covariância foi satisfeita ($\alpha+\beta<1$). Tal condição significa que a volatilidade de longo prazo reduz a persistência no componente de curto prazo (Mo et al, 2018; Conrad, Custovic e Ghysels (2018). Contudo, cabe ressaltar que para a China o parâmetro *alfa* (α), na regressão em que a variável independente é o índice EPU, não foi estatisticamente significativo. Tal resultado diverge do encontrado por Mo et al. (2018), uma vez que esses autores afirmaram que, apesar das variáveis macroeconômicas terem pouco impacto na volatilidade dos mercados futuros de *commodities*, as incertezas das variáveis macroeconômicas, tanto domésticas quanto internacionais, são determinantes importantes dessas volatilidades.

Após tal verificação, a análise deve basear-se nos parâmetros mais interessantes para a pesquisa que aplica a modelagem GARCH-MIDAS: os parâmetros de inclinação *teta* (θ), segundo Engle, Ghysels e Sohn (2013).

Para o modelo GARCH-MIDAS, com base, exclusivamente, na volatilidade realizada, os resultados evidenciaram que, para todos os países aqui analisados, o parâmetro θ apresentou coeficiente positivo, além de ser fortemente significativo.

Para as estimações que utilizaram como regressor o índice EPU e o CPI, individualmente, os resultados para θ indicaram uma relação positiva entre tais variáveis e a volatilidade dos retornos dos mercados acionários de cada país, sendo tais resultados consistentes com os achados de Yu et al. (2017), Mo et al. (2018) e Fang, Yu e Xiao (2018), especificamente para a variável EPU. Contudo, para a Rússia, a variável EPU não foi estatisticamente significativa e, para a China, a variável CPI também não mostrou significância estatística. Ao focar nos resultados dos países Brasil e Índia, que tiveram tanto o índice EPU, como o CPI estatisticamente significativos, é possível verificar que, para o Brasil, de acordo com os critérios informacionais *Akaike* e *Bayesiano*, o modelo mais adequado para modelar a volatilidade dos retornos do índice representativo do seu mercado acionário é o que utiliza como regressor o índice EPU; para a Índia, é o que utiliza o CPI.

Ainda é possível verificar, com base nos critérios informacionais *Akaike* e *Bayesiano*, que para o Brasil e para a Rússia, os modelos com base apenas na volatilidade realizada foram melhorados com a inclusão das variáveis macroeconômicas EPU e CPI. Porém, o mesmo não foi observado para os países Índia e China.

Após as estimações, foram realizadas as projeções da volatilidade dos retornos das bolsas dos países integrantes do BRIC, via modelo MIDAS-GARCH, considerando: 1º) exclusivamente a volatilidade realizada; 2º) a inclusão do índice EPU; e 3º) a inclusão do CPI, para cada país. Foram realizadas projeções fora da amostra por janela recursiva, até 3 passos à frente. Segundo Gonzalez-Riviera (2013), ao utilizar a janela recursiva, o modelo é estimado com t observações e a projeção 1 passo à frente é realizada. Para o próximo período, a amostra de estimativa aumenta em mais 1 (uma) observação, e o modelo é estimado novamente com $t + 1$ observações. No tempo $t + 1$, novamente é elaborada a projeção 1 passo à frente.

Para a análise da acurácia das projeções dos modelos, a raiz do erro quadrático médio (RMSE) foi aplicada. A Tabela 2 apresenta os resultados desse teste.

Tabela 2 – Resultados das projeções da volatilidade dos retornos a partir dos modelos GARCH-MIDAS

Variável Projetada	Projeções	Variável dependente	RMSE			
			BRASIL	RÚSSIA	ÍNDIA	CHINA
Volatilidade dos retornos acionários	h=1	RV	0,0007480	0,0018830	0,0006838	0,0006668
	h=2		0,0007479	0,0018820	0,0006836	0,0006667
	h=3		0,0007478	0,0018820	0,0006835	0,0006666
	h=1	EPU	0,0007443	0,0018750	0,0007260	0,0034490
	h=2		0,0007518	0,0018870	0,0006874	0,0006761
	h=3		0,0007517	0,0018860	0,0006873	0,0006760
	h=1	CPI	0,0007602	0,0018930	0,0006877	0,0006987
	h=2		0,0007753	0,0019110	0,0006956	0,0006844
	h=3		0,0007752	0,0019110	0,0006955	0,0006842

Fonte: Elaboração própria com base nos resultados do *MatlabR2018a*.

Ao analisar Tabela 2, é possível verificar que as projeções baseadas exclusivamente na volatilidade realizada, para 2 e 3 passos à frente, superaram as projeções que incluíram as variáveis macro. Contudo, para o Brasil, Rússia e China, as projeções 1 passo à frente, dos modelos que incluíram a variável EPU, obtiveram um melhor poder de projeção da volatilidade dos retornos acionários. Especificamente para o Brasil, esse achado é corroborado com o estudo de Costa Filho (2014). A exceção foi a Índia, que apresentou uma melhor projeção com o modelo baseado apenas na volatilidade realizada.

Ademais, comparando os modelos que incluíram as variáveis macro, para o Brasil, o modelo GARCH-MIDAS com a inclusão da variável EPU teve melhor poder de projeção da volatilidade dos retornos do índice Bovespa, do que o modelo que inclui o CPI. O mesmo é verificado para a Rússia e para a China, já que seus erros de projeção são menores quando EPU é o regressor. Por outro lado, para a Índia, na projeção 1 passo à frente, o modelo com melhor poder de projeção foi o que adicionou a variável explicativa CPI. Porém, para 2 e 3 passos à frente, o modelo com a variável EPU mostrou-se mais apropriado para a projeção da volatilidade dos retornos do índice representativo do seu mercado acionário.

5. Conclusão

Este artigo teve por objetivo estudar o efeito de duas variáveis: o EPU e a CPI (*proxy* de incerteza econômica), individualmente, sobre a volatilidade do mercado acionário dos países pertencentes ao BRICS, com a aplicação do modelo GARCH-MIDAS, além de propor uma projeção dessa volatilidade com base naquelas variáveis, para os países pertencentes ao BRICS, com exceção da África do Sul.

Em resumo, é possível sugerir que o índice representativo da incerteza política e econômica é mais indicado para a projeção da volatilidade dos índices representativos dos mercados acionários dos países integrantes do BRIC, se comparado à inflação, *proxy* para a incerteza econômica, conforme supramencionado. Ademais, a projeção 1 passo à frente a partir do modelo que adiciona a variável EPU, supera, em geral, a projeção baseada na volatilidade realizada. Tais resultados permitem sugerir que a incerteza política tem uma relação direta com o mercado de capitais, uma vez que esse fornece serviços essenciais para o desenvolvimento econômico de um país.

As descobertas desta pesquisa contribuem para a literatura existente estendendo essa área de pesquisa para o BRIC, além de ajudar os formuladores de políticas em suas decisões. Por fim, espera-se que tais descobertas sejam úteis para as decisões de alocação de ativos, especialmente para investimentos em setores com preocupações de longo prazo, uma vez que a variável EPU tem destaque nesse contexto.

Referências Bibliográficas

Akinkugbe, O. (2005). Efficiency in Bostwana stock Exchange: An empirical analysis. Cambridge. *The Business Review*, 4(2): 223-230.

Amendola, A., Candila, V., Gallo, M.G. (2018). On the asymmetric impact of macro-variables on volatility. Article in press. *Economic Modelling*: 1-18.

Andreou, E.; Ghysels, E.; Kourtellos, A. (2010). Regression models with mixed sampling frequencies. *Journal of Econometrics*, 158:246-261.

Andreou, E.; Ghysels, E.; Kourtellos, A. (2013). Should Macroeconomic Forecasters Use Daily Financial Data and How? *Journal of Business & Economic Statistics*, 31(2):240-251.

Asgharian, H.; Hou, A. J.; Javed, F. (2013). Importance of the macroeconomic variables for variance prediction: A GARCH-MIDAS approach. *Journal of Forecasting*, 32(7), 600-612.

Brandt, M. W. and Kang, Q. (2004). On the relationship between the conditional mean and volatility of stock returns: A latent VAR approach. The Wharton School. *Journal of Financial Economics*, 72 (2): 217–257.

Brzeszczynski, J.; Gajdka, J.; Kutun, A. M. (2015). Investor response to public news, sentiment and institutional trading in emerging markets: A review. *International Review of Economics and Finance*, 40: 338–352.

Chambers, M. J. (2016). The estimation of continuous time models with mixed frequency data. *Journal of Econometrics*, 193(2):390-404.

Chen, G; Firth, M; Rui, O. M. (2001). The dynamic relation between stock returns, trading volume and volatility. *The Financial Review*, 36(3): 153-174.

Conrad, C.; Custovic, A.; Ghysels, E. (2018). Long- and Short-Term Cryptocurrency Volatility Components: A GARCH-MIDAS Analysis. *Journal of Risk and Financial Management*, 11(23): 1-12.

Costa, F. A. E. (2014) Incerteza e Atividade Econômica no Brasil. *Economia Aplicada*, 18(3): 421-453.

Robert F. Engle, R. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50 (4): 987-1007.

Engle, R.F., Rangel, J.G. (2008). The spline-GARCH model for low-frequency volatility and its global macroeconomic causes. *The Review of Financial Studies*, 21(3): 1187-1222.

Engle, R.F., Ghysels, E., Sohn, B. (2013). Stock market volatility and macroeconomic fundamentals. *Review of Economics and Statistics*, 95 (3): 776–797.

Revista Exame (2016). Disponível em: <https://exame.abril.com.br/revista-exame/a-china-pode-estar-na-rota-da-crise-para-azar-do-brasil/>>. Acesso: 05/2018.

Fang, L., Yu, H., Xiao, W. (2018). Forecasting gold futures market volatility using macroeconomic variables in the United States. *Economic Modelling*, 72: 249-259.

Gaetano, D. Forecast Combinations for Structural Breaks in Volatility: Evidence from BRICS Countries. (2018). *Journal Risk Financial Management*, 11(64): 1-13.

Ghysels, E.; Plazzi, A.; Valkanov, R. (2016). Why Invest in Emerging Markets? The Role of Conditional Return Asymmetry. *The Journal of Finance*, 71(5):2145-2192.

Ghysels, E.; Santa-Clara, P.; Valkanov, R. (2004). The MIDAS touch: Mixed data sampling regression models. *Finance*.

Ghysels, E.; Santa-Clara, P.; Valkanov, R. (2005). There is a risk-return tradeoff after all. *Journal of Financial Economics*, 76:509–548.

Ghysels, E., Sinko, A. and Valkanov, R. (2007). MIDAS regression: Further results and new directions. *Journal Econometric Reviews*, 26: 53-90.

Girardin, E.; Joyeux, R. (2013). Macro fundamentals as a source of stock market volatility in China: a GARCH-MIDAS approach. *Economic Modelling*, 34, 59-68.

Gulen, H.; Ion, M. (2016). Policy uncertainty and corporate investment. *The Review of Financial Studies*,. 29 (3): 523-564.

Javed, F; Hou, A. J.; Ascharian, H. (2013). Importance of macroeconomic variables for variance prediction: A GARCHMIDAS approach. *Journal of forecasting*, 32(7): 1-25.

Kedia, B. L.; Rhew, N. D.; Gaffney, N. T.; Clampit, J. A. (2015). Emerging Market Multinationals: Cooperation for Global Growth. *Thunderbird International Business Review*, 58(6): 515-526.

Mo, D.; Gupta, R.; Li, B.; Singh, T. (2018). The macroeconomic determinants of commodity futures volatility: Evidence from Chinese and Indian markets. *Economic Modelling*, 70: 543–560.

Morales, L.; Gassie-Falzone, E. (2011). Structural Breaks and Financial Volatility: Lessons from BRIC Countries. *Paper presented at IAMO Forum 2011*, Halle (Saale), Germany, June 23–24. pp. 1–31. Disponível em: <https://www.econstor.eu/obitstream/10419/50791/1/67077491X.pdf>.

Pan, Z.; Wang, Y.; Wu, C.; Yin, L. (2017). Oil price volatility and macroeconomic fundamentals: A regime switching GARCH-MIDAS model. *Journal of Empirical Finance*, 43: 130-142.

Perez-Quiros, G. and Timmermann, A. (2002). Firm size and cyclical variations in stock returns. *Journal of Finance*, 55:1229-1262.

Nader Virk, N.; Javed, F. (2017). European equity market integration and joint relationship of conditional volatility and correlations. *Journal of International Money and Finance* 71: 53–77.

Yin, L., Zhou, Y. (2016). What drives long-term oil market volatility? Fundamentals versus Speculation. *Economics*, 10(20): 1-27.

Yu, Honghai., Fang, Libing., Du, Donglei., Yan, Panpan (2017). How EPU drives long-term industry beta. *Finance Research Letters*, 22: 249–258.

Zheng, Z., Qiao, Z., Takaishi, T., Stanleu, E. H., LI, B (2014). Realized Volatility and Absolute Return Volatility: A Comparison Indicating Market Risk. *PLoS ONE*, 19(7).