



www3.unicentro.br

Revista Capital Científico – Eletrônica (RCCe)

ISSN 2177-4153

Disponível em: revistas.unicentro.br/index.php/capitalcientifico/index



www3.unicentro.br/ppgadm/

Análise dinâmica de volatilidade para os setores do mercado acionário brasileiro: uma aplicação do modelo MRS-Garch

Dynamic analysis of volatility for the brazilian stock market sector: a application of MRS-Garch model

Bruno Pereira Conte¹

¹ Universidade Federal de Santa Maria, Brasil, Mestrado em Administração, e-mail: b.conte@ufn.edu.br

Recebido em: 14/04/2020 - Revisado em: 10/10/2020 - Aprovado em: 12/02/2021 - Disponível em: 01/04/2021

Resumo

Nesse artigo, foi proposta uma análise da dinâmica de volatilidade nos setores do mercado acionário brasileiro, fazendo-se assim um estudo nos principais índices setoriais da BM&F Bovespa. Utilizou-se o modelo de regimes de Markov. Como resultados, inicialmente se observou a ausência de efeito alavancagem na maioria dos regimes das séries. Além disso, houve um predomínio de assimetria bem como a persistência de volatilidade para a maior parte dos regimes dos índices. Notou-se também uma grande similaridade entre o mercado brasileiro e o setor Financeiro, sendo ambos com regimes muito próximos, além de possuírem volatilidade com característica de maior persistência após o ano de 2013. Outra similaridade encontrada foi entre o setor de Utilidade Pública e o setor de Energia Elétrica, ambos caracterizados pela grande alternância entre os regimes estimados. Assim, foi possível concluir que cada setor do mercado acionário brasileiro tem um comportamento distinto, captado pelos diferentes regimes estimados.

Palavras-chave: Índices setoriais; Mercado brasileiro; Volatilidade; Regimes de volatilidade

Abstract

In this study, a analysis the dynamic of volatility was proposed in the Brazilian stock market sectors, thus making a study in the main sector indexes of BM&FBovespa. It was used the model of Markov Switching Regimes. As results, initially we observed the absence of leverage effect in the most part of the series. In addition, there was a predominance of asymmetry as well as the persistence of volatility for most part of regimes from the series. It was observed too, that there was a great similarity between the Brazilian stock market and the Financial sector, both with very closely regimes, besides having volatility with a characteristic of greater persistence after the year of 2013. Another similarity found was between the Public

Utilities sector and the Electric Energy sector, both characterized by the great alternation between the estimated regimes. Thus, it was possible to conclude that each sector of the Brazilian stock market has a different behavior, captured by the different estimated regimes.

Keywords: Sector indexes; Brazilian stock market; Volatility; Switching volatility regimes

1 Introdução

O estudo da volatilidade em séries financeiras se tornou popular a partir dos estudos pioneiros de Engle (1982) e Bollerslev (1986), que estimaram os modelos ARCH (*Autorregressive conditional heteroskedasticity*) e GARCH (*Generalized autorregressive condicional heteroskedasticity*). A razão pela qual estes modelos passaram a ser amplamente utilizados foi, segundo Reher e Wilfling (2011), a compatibilidade que os modelos GARCH têm com as séries de retornos financeiros, a existência de métodos estatísticos eficientes para estimar os parâmetros do modelo, e a existência de disponibilidade de previsões úteis para a volatilidade.

A fim de se buscar modelos específicos para cada tipo de volatilidade como o efeito alavancagem (*leverage*) e fatos estilizados, diversas especificações de modelos GARCH foram desenvolvidas. Os modelos EGARCH de Nelson (1991), TGARCH de Zakoian (1994) e o GJR-GARCH de Glosten *et al.* (1993) consideram assimetrias e choques de volatilidade. Já o modelo FIGARCH de Baille *et al.* (1996) é considerado de memória longa, isto é, incorpora a volatilidade e o tempo à previsão de retorno financeiro além de considerar quebras estruturais às séries.

Embora os modelos EGARCH, TGARCH e GJR-GARCH assumam a possibilidade de ocorrer assimetria na volatilidade, eles operam em apenas um regime para captarem a alta persistência na volatilidade, ou seja, ajustam-se à série histórica com apenas um padrão, ignorando possíveis mudanças estruturais potenciais. Cai (1994) e Hamilton e Susmel (1994) introduzem o processo de mudança de regime (Hamilton, 1988, 1989) no modelo GARCH, a fim de considerar possíveis quebras estruturais. Em particular, o modelo *Markov Regime Switching* MRS-GARCH permite que os regimes da cadeia de Markov tenham diferentes comportamentos GARCH, ou seja, diferentes estruturas de volatilidade, para ampliar o ajuste dos modelos GARCH às formas dinâmicas e realizar melhores estimativas e desempenho de previsão (KLAASSEN, 2002; HAAS *et al.*, 2004; MARCUCCI, 2005; ZHANG & WANG, 2015; ZHANG & ZHANG, 2015).

Segundo Reher e Wilfling (2011), os modelos GARCH com mudança regime são projetados para capturar mudanças discretas no processo de volatilidade dos dados da série, e são amplamente utilizados em séries temporais. Alguns estudos dessa abordagem fazem uso de preços de *commodities*, como os de Alizadeh *et al.* (2008), Henry (2009), Bohl *et al.* (2011) e Zhang, Yao & He (2015). Outros trabalhos fazem uso de séries de retorno de algumas companhias listadas na bolsa de valores, como é o caso de Reher e Wilfling (2011) aplicado no mercado alemão e o de Chlebus (2016), que analisou o mercado Polonês, especificamente companhias listadas na bolsa de Varsóvia.

Ao observar a diferença entre os modelos GARCH de um regime e os de Markov, esse artigo tem o objetivo de estudar a dinâmica do comportamento da volatilidade do mercado

brasileiro em diferentes regimes. Para tal, serão estudados os índices setoriais da Bolsa de Valores, Mercadorias e Futuros de São Paulo (BM&F Bovespa) devidamente referenciados com base na literatura a fim de captar o comportamento da volatilidade de cada setor. A principal contribuição desse trabalho é a de analisar a dinâmica da volatilidade nos setores sob a perspectiva de diferentes regimes, o que pode gerar parâmetros que possibilitem efetuar uma análise diferenciada quanto à característica idiossincrática do mercado acionário brasileiro.

2 Metodologia

Os procedimentos metodológicos desse artigo se dividem em três tópicos: apresentação do modelo MRS-GARCH, os procedimentos estatísticos que permitem estimação da modelagem proposta e a apresentação, quantificação e descrição dos dados utilizados para esse estudo.

2.1 Modelo MRS-GARCH

Fazendo-se uso da definição de Kritzman *et al.* (2012) e aplicada por Günay (2015), os diferentes regimes da cadeia de Markov são representadas pela equação (1).

$$\Pr(X_i = i) = p_i,$$

onde, x_i é o primeiro regime na cadeia de Markov. A seguir, será demonstrada a probabilidade de mudança de regimes, em que representa os parâmetros de transição de regime em cada matriz.

$$\Gamma = \begin{pmatrix} \gamma_{11} & \gamma_{12} \\ \gamma_{21} & \gamma_{22} \end{pmatrix},$$

e

$$\gamma_{ij} = \Pr(X_i = j | X_{t-1} = i),$$

onde t denota o tempo. Assim, a cadeia de Markov estará no regime $X_i = 1$ ou $X_i = 2$ no tempo. Cada regime apresenta observações, e de acordo com a distribuição π_i . Tal distribuição pode ser explicada a seguir.

$$\pi_i = \Pr(\gamma_i = s | X_i = i),$$

logo, o que se demonstra é que no regime, , dita a probabilidade de ter um valor s específico.

Os modelos GARCH podem seguir a distribuição normal de *t-student* ou com assimetria. As demonstrações que seguem foram estabelecidas por Ardia *et al.* (2017).

A distribuição normal do modelo é dada por.

$$f_s(\eta) \equiv \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}\eta^2}, \quad \eta \in$$

Já a distribuição de *t-student* é apresentada a seguir.

$$f_s(\eta, v) = \frac{\Gamma\left(\frac{v+1}{2}\right)}{\sqrt{(v-2)\pi}\Gamma(v/2)^{1/2}} \cdot \left(1 + \frac{\eta^2}{v-2}\right)^{-\frac{v+1}{2}}, \quad \eta \in$$

onde estabelece a função *Gamma*. Impõe-se $v > 2$ para garantir que a distribuição siga o modelo *t-student*.

Por fim, têm-se a possibilidade de se incorporar a assimetria nas distribuições, como foi desenvolvido por Fernandez e Steel (1998), que usa uma função densidade, , para construir uma função de densidade de probabilidade assimétrica.

$$f(\varepsilon_t | \gamma) = \frac{2}{\gamma - \gamma^{-1}} \left[f\left(\frac{\varepsilon_t}{\gamma} | I_{(0, \infty)}(\varepsilon_t)\right) + f(\varepsilon_t \gamma | I_{(-\infty, 0)}(\varepsilon_t)) \right]$$

A função assimetria pode ser aplicada tanto na distribuição normal, quanto na distribuição *t-student*.

O modelo propriamente dito segue o processo GARCH, que pode ser especificado na equação.

$$r_t = \delta + \varepsilon_t; \quad \varepsilon_t = \eta_t \sqrt{h_t}; \quad h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta h_{t-1}$$

A partir da equação acima, define-se o modelo EGARCH, que é estimado conforme o exposto na equação seguinte.

$$\ln(h_{i,t-1}) = \alpha_{0,i} + \alpha_1 (\eta_{i,t-1} - E[|\eta_{i,t-1}|]) + \alpha_{2,i} \varepsilon_{i,t-1}^2 + \beta \ln(h_{i,t-1}).$$

Caso $\alpha_1 < 0$, segundo Wennström (2014), corrobora o efeito *leverage*. Além disso, caso o parâmetro α_1 seja estatisticamente significativo e diferente de zero, há a observância de um efeito assimetria. Esse é efeito se caracteriza pela diferença de respostas a choques nas séries, isto é, um choque positivo não tem o mesmo efeito de um choque negativo de mesma magnitude. Segundo Alexander et al. (2009), o termo β é o parâmetro que mede a persistência da volatilidade, sendo que, quanto maior o valor desse, mais intensa é a volatilidade e sua persistência perdura por mais tempo.

Dado os modelos expostos nas equações (8) e (9), apresenta-se a modelagem MRS-GARCH, exposta nas 3 equações a seguir.

$$r_t = \mu_1^{(i)} + \varepsilon_t = \delta^{(i)} + \varepsilon_t; \quad \eta_t \sqrt{h_t};$$

$$h_t^{(i)} = \alpha_0^{(i)} + \alpha_1^{(i)} \varepsilon_{t-1}^2 + \beta_1^{(i)} E_{t-1} \{ h_{t-1}^{(i)} | s_1 \};$$

$$E_{t-1} \{ h_{t-1}^{(i)} | s_1 \} = p_{ii,t-1} \left[(\mu_{t-1}^{(i)})^2 + h_{t-1}^{(i)} \right] + p_{ji,t-1} \left[(\mu_{t-1}^{(j)})^2 + h_{t-1}^{(i)} \right] - \left[p_{ii,t-1} \mu_{t-1}^{(i)} + p_{ji,t-1} \mu_{t-1}^{(i)} \right]^2.$$

Em que $i, j = 1, 2$ define os dois regimes do modelo MRS-GARCH,

$$p_{ji,t} = \Pr(s_t = j | s_{t+1} = i, \zeta_{t-1}) = \frac{P_{ji} \Pr(s_t = j | s_{t+1} = j, \zeta_{t-1})}{\Pr(s_{t+1} = i | \zeta_{t-1})} = \frac{p_{ji} p_{j,t}}{p_{i,t+1}}$$

ζ_{t-1} representa as informações em $C - 1$.

2.2 Modelo Auto-regressivo AR(p)

Os modelos auto-regressivos foram criados com a ideia de que a presente observação da série z_t pode ser explicada como uma função das p observações passadas, $z_{t-1}, z_{t-2}, z_{t-p}$, onde p determina o número de passos entre as observações passadas e a previsão da próxima observação.

A estrutura auto regressiva geral é expressa por.

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} +$$

Em que ϕ_i são parâmetros, (i, \dots, p) são as ordens de defasagem do modelo $AR_{(p)}$, e a_t é o ruído branco com média zero e variância σ_a^2 .

2.3 Teste Ljung-Box

O objetivo da metodologia Box & Jenkins é determinar os componentes que configuram os parâmetros (p) do modelo auto regressivo. Inicialmente se deve tornar a série estacionária a partir da construção da diferença logarítmica das séries, conforme a equação .

$$I = \log(I_{i-1} - I_i)$$

A seguir, identifica-se os parâmetros p por meio das funções de autocorrelação (ACF) e de autocorrelação parcial (PACF) estimadas, e a estimação dos parâmetros $(\phi_i, i = 1 \dots p)$. A função de autocorrelação segue a função expressa na equação seguinte.

$$\rho_k = \frac{\gamma_k}{\gamma_0}; \quad k = 0, 1, 2, \dots$$

Em que $\gamma_0 = \text{var}(Z_t)$. Para tal, estima-se o número de defasagens (*lags*) para o modelo auto regressivo.

2.4 Dados

Para analisar a dinâmica da volatilidade nos setores do mercado acionário brasileiro, foram coletados dados dos sete índices setoriais da Bovespa. Além do Índice Ibovespa, que representada o mercado acionário brasileiro, compõem a amostra o Índice Financeiro, Índice Imobiliário, Índice de Utilidade pública, Índice de Consumo, Índice de Energia Elétrica, Índice de Materiais e o Índice Industrial. Foram coletados os valores de cotação de todos os índices, do dia 04 de Janeiro de 2012 até o dia 12 de Dezembro de 2017 com periodicidade semanal, o que totalizou um universo de 1.502 observações de cada índice, gerando uma amostra com o total de 12.016 observações.

O Índice Bovespa (IBOV) é o principal indicador do mercado brasileiro de ações que valida o desempenho médio das cotações das ações negociadas na Bolsa de Valores de São Paulo. É formado pelas ações com maior volume negociado nos últimos meses.

O Ibovespa tem por objetivo ser o indicador do desempenho médio das cotações dos ativos de maior negociabilidade e representatividade do mercado de ações brasileiro (BM&FBOVESPA, 2018).

O Índice Financeiro (IFNC) tem como meta proporcionar uma visão focalizada do mercado acionário, medindo o comportamento das ações das empresas representativas dos setores de intermediários financeiros, serviços financeiros diversos e previdência e seguros.

As ações componentes são selecionadas por sua liquidez, e são ponderadas nas carteiras pelo valor de mercado das ações disponíveis à negociação. São incluídas na carteira do índice as ações que atenderem aos seguintes critérios, com base nos doze meses anteriores: i) inclusão em uma relação de ações cujos índices de negociabilidade somados representem 98% do valor acumulado de todos os índices individuais; ii) participação em termos de presença em pregão igual ou superior a 95% no período (BM&F/BOVESPA, 2018).

O Índice Imobiliário (IMOB) tem por objetivo ser o indicador do desempenho médio das cotações dos ativos de maior negociabilidade e representatividade dos setores da atividade imobiliária compreendidos por exploração de imóveis e construção civil. São selecionados para compor o Índice Imobiliário os ativos que devem estar entre os ativos elegíveis que, no período de vigência das 3 carteiras anteriores, representem em conjunto 99% do somatório total desses indicadores e ter presença em pregão de 95 no período de vigência das 3 (três) carteiras anteriores; não ser classificado como "*Penny Stock*"; além de pertencer aos setores da atividade imobiliária compreendidos por exploração de imóveis e construção civil (BM&FBOVESPA, 2018).

O Índice de Utilidade Pública (UTIL) é o indicador do desempenho médio das cotações dos ativos de maior negociabilidade e representatividade do setor de utilidade pública (energia elétrica, água e saneamento e gás). Compõem o UTIL os ativos elegíveis que, no período de vigência das 3 (três) carteiras anteriores, em ordem decrescente de Índice de Negociabilidade, representem em conjunto 99% do somatório total desses indicadores além de ter presença em pregão de 95% no período de vigência das 3 carteiras anteriores. (BM&FBOVESPA, 2018).

O Índice de Consumo (ICON) objetiva ser o indicador do desempenho médio das cotações dos ativos de maior negociabilidade e representatividade dos setores de consumo cíclico, consumo não cíclico e saúde. Compõem o ICON os ativos elegíveis que, no período de vigência das 3 carteiras anteriores, representem em conjunto 99% do somatório total desses indicadores, ter presença em pregão de 95% no período de vigência das 3 carteiras anteriores e pertencer aos setores de consumo cíclico, consumo não cíclico e saúde (BM&FBOVESPA, 2018).

O Índice de Energia Elétrica (IEE) é o indicador do desempenho médio das cotações dos ativos de maior negociabilidade e representatividade do setor de energia elétrica. São selecionados para compor o IEE, os ativos que atendam cumulativamente: ter participação em termos de volume financeiro maior ou igual a 0,01% no mercado a vista (lote-padrão) no período de vigência das 3 carteiras anteriores, ter presença em pregão de 80% no período de vigência das 3 carteiras anteriores, ter apresentado no mínimo 2 negócios/dia em pelo menos 80% dos pregões em que foi negociada e pertencer ao setor de energia elétrica (BM&FBOVESPA, 2018).

O Índice de Materiais (IMAT) objetiva ser o indicador do desempenho médio das cotações dos ativos de maior negociabilidade e representatividade do setor de materiais básicos.

Compõem o IMAT os ativos elegíveis que, no período de vigência das 3 carteiras anteriores, representem em conjunto 99% do somatório total desses indicadores, ter presença em pregão de 95% no período de vigência das 3 carteiras anteriores e pertencer ao setor de materiais básicos (BM&FBOVESPA, 2018).

O Índice Industrial (INDX) foi desenvolvido com o objetivo de medir o desempenho das ações mais representativas do setor industrial, importante segmento da economia brasileira. Sua carteira teórica é composta das ações mais representativas da indústria.

Serão selecionados para compor o INDX os ativos que atendam cumulativamente: estar entre os ativos elegíveis que, no período de vigência das 3 carteiras anteriores e ocupem as 150 primeiras posições, ter presença em pregão de 95% no período de vigência das 3 carteiras anteriores e pertencer aos setores da atividade industrial compreendidos por materiais básicos, bens industriais, consumo cíclico, consumo não cíclico, tecnologia da informação e saúde.

4 Análise e discussão dos resultados

Inicialmente, optou-se por aplicar a diferença logarítmica das séries com o intuito de as tornar estacionárias. Com isso, analisa-se as estatísticas descritivas da amostra apresentadas na Tabela 1.

Ao se analisar a média, observa-se que apenas o IMOB tem valor negativo, o que permite inferir que esse foi o único dos setores entre os analisados que sofreu uma retração (menor retorno médio) no período, diferente do IFNC, que é o indicador de maior retorno médio no período.

Os valores de mínimo e máximo também confirmam essa tendência, pois IMOB é o que tem o menor valor e o IFNC é o maior. Nota-se que o IMAT é o setor de maior desvio padrão médio, sendo assim, o mais volátil. Em relação à curtose, os índices IFNC, UTIL, IEE e IMOB apresentaram curva leptocúrtica ($\text{curtose} > 3$), o que torna essas séries mais distantes de um comportamento de distribuição normal. As demais seguem o comportamento platicúrtico ($\text{curtose} < 3$), descaracterizando o comportamento de distribuição normal.

Somado a isso tem-se a assimetria, em que a maior parte das variáveis têm comportamento assimétrico negativo (assimetria < 0), isto o que somado à curtose confere às séries financeiras o comportamento de “caudas gordas”.

Tabela 1 – Estatísticas descritivas das diferenças logarítmicas semanais dos índices setoriais do mercado acionário brasileiro (2012-2017)

	Média (x100)	Mínimo	Máximo	Desvio padrão	Curtose	Assimetria
IBOV	0,017	-0,101	0,081	0,023	2,400	-0,027
IFNC	0,055	-0,121	0,093	0,023	4,166	-0,083
UTIL	0,022	-0,117	0,052	0,012	5,397	-0,795
ICON	0,050	-0,072	0,052	0,018	2,422	-0,183
IEE	0,012	-0,113	0,057	0,014	5,441	-0,761
IMAT	0,026	-0,084	0,077	0,029	0,963	0,124
INDX	0,028	-0,059	0,059	0,010	1,272	0,023
IMOB	-0,004	-0,149	0,067	0,023	5,385	-0,495

Fonte: Os autores

Na Tabela 2 são apresentados os resultados do modelo auto-regressivo $AR(p)$ com o objetivo de eliminar a dependência auto – regressiva nas séries.

Para estimar o número de defasagens utilizou-se os testes ACF e PACF que definiram os parâmetros p para cada índice. Após estimado o modelo $AR(p)$, testou-se a autocorrelação dos resíduos das séries pelo critério de Ljung-Box com até 8 defasagens. Observando-se as estimações do Chi quadrado e o p -valor, não é encontrado mais evidências de autocorrelação nos resíduos do modelo $AR(p)$.

Tabela 2 – Definição das lags (p) e as estatísticas de autocorrelação dos resíduos do modelo $AR(p)$

	IBOV	IFNC	UTIL	ICON	IEE	IMAT	INDEX	IMOB
$AR(p)$	4	4	4	5	4	0	5	4
Chi ² *	2,315	2,746	3,661	6,719	3,483	4,736	1,948	4,852
p-valor*	0,132	0,107	0,062	0,248	0,076	0,701	0,602	0,313

*** Valores referentes aos resíduos oriundos do modelo auto-regressivo $AR(p)$**

Com os resíduos livres de autocorrelação, partiu-se para a estimação dos modelos de mudança de regime Markovianos.

A Tabela 3 apresenta os resultados encontrados para cada índice setorial, em que cada modelo estimado foi elencado a partir dos critérios de informação AIC de Akaike (1974) e BIC de Schwartz (1976), os quais definiram os modelos EGARCH com 2 regimes de Markov os de melhor ajuste para todos os índices.

Tabela 3 – Resultados estimados do modelo MRS-EGARCH para o Ibovespa e setores do mercado acionário brasileiro**

	Setores do mercado acionário brasileiro							
	IBOV (t_s)	IFNC (t_s)	UTIL (n)	ICON (t_s)	IEE (n)	IMAT (t_s)	INDEX (t_s)	IMOB (t)
$\alpha_0^{(1)}$	-0,567* (0,047)	-0,210* (0,005)	-0,149* (0,005)	-2,084 (1,143)	-0,197* (0,003)	-0,118* (0,001)	-7,096* (0,001)	-1,933* (0,026)
$\alpha_1^{(1)}$	0,078* (0,003)	0,030* (0,001)	0,068* (0,001)	0,011* (0,013)	0,078* (0,001)	0,044* (0,001)	-0,302* (0,001)	0,225* (0,003)
$\alpha_2^{(1)}$	0,023* (0,002)	-0,030* (0,000)	-0,036* (0,000)	-0,010* (0,003)	-0,039* (0,000)	-0,049* (0,000)	-0,053* (0,001)	0,073* (0,002)
$\beta^{(1)}$	0,934* (0,006)	0,976* (0,001)	0,984* (0,001)	0,782* (0,120)	0,979* (0,000)	0,986* (0,000)	0,262* (0,000)	0,770* (0,003)
$u_1^{(1)}$	4,555* (0,035)	8,237* (0,055)	-	12,095* (0,143)	-	10,286* (0,087)	30,931* (0,024)	4,644* (0,030)
$u_2^{(1)}$	1,164* (0,002)	0,939* (0,001)	-	1,023* (0,002)	-	0,876* (0,001)	1,006* (0,001)	-
$\alpha_0^{(2)}$	-0,131* (0,002)	-0,229* (0,007)	-1,283* (0,005)	-1,359* (0,026)	-0,316* (0,002)	-0,094* (0,002)	-0,051* (0,000)	-0,144* (0,003)
$\alpha_1^{(2)}$	0,102* (0,001)	0,087* (0,001)	0,221* (0,004)	0,033* (0,002)	0,228* (0,003)	0,087* (0,001)	0,001* (0,000)	0,126* (0,001)
$\alpha_2^{(2)}$	-0,036* (0,000)	0,037* (0,001)	-0,622* (0,006)	-0,123* (0,002)	-0,338* (0,003)	0,073* (0,001)	-0,083* (0,001)	-0,042* (0,001)
$\beta^{(2)}$	0,984* (0,000)	0,969* (0,001)	0,811* (0,001)	0,841* (0,003)	0,947* (0,000)	0,987* (0,000)	0,994* (0,000)	0,983* (0,000)
$u_1^{(2)}$	23,412* (0,402)	8,133* (0,133)	-	11,373* (0,162)	-	57,573* (4,659)	16,374* (0,015)	72,100* (3,510)
$u_2^{(2)}$	0,851* (0,001)	0,926* (0,002)	-	0,925* (0,002)	-	1,181* (0,002)	0,902* (0,001)	-
Matriz de transição								
P_1_1	0,998* (0,000)	0,997* (0,000)	0,957* (0,002)	0,991* (0,000)	0,943* (0,001)	0,999* (0,000)	0,975* (0,000)	0,994* (0,000)
P_2_2	0,999* (0,000)	0,987* (0,000)	0,609* (0,000)	0,985* (0,000)	0,557* (0,000)	0,996* (0,000)	0,983* (0,000)	0,996* (0,000)
Proporção dos regimes								
Regime_1	0,278	0,794	0,902	0,618	0,886	0,775	0,412	0,418
Regime_2	0,723	0,206	0,099	0,382	0,114	0,225	0,588	0,582
Volatilidade Condicional média								
Regime_1	0,215	0,221	0,212	0,152	0,196	0,255	0,154	0,237
Regime_2	0,245	0,320	0,247	0,197	0,221	0,316	0,178	0,244
Crítérios de ajuste dos modelos								
AIC:	-8.382	-8.356	-8.869	-9.421	-9.062	-8.032	-9.411	-8.384
BIC:	-8.307	-8.281	-8.816	-9.347	-9.009	-7.958	-9.337	-8.320

Erro padrão representado entre (); * p -valor < 0,05; ** (n) distribuição normal, (t) distribuição t -student, (t_s) distribuição t -student com assimetria; : Regime 1; : Regime 2

O IBOV apresenta assimetria na volatilidade devido à significância estatística do termo . Entretanto, pela razão de todos os valores de serem maiores que zero, não há evidência de efeito alavancagem para essa série em ambos regimes. Ainda, nota-se um aumento de 30% nesse parâmetro no segundo regime, o que acentua o impacto assimétrico sobre a volatilidade futura.

Além disso, o Índice Ibovespa apresenta comportamento de volatilidade impactada pelos choques passados, visto que o parâmetro é estatisticamente significativo. Entretanto, enquanto no regime 1 há respostas positivas a choques negativos na série, ou seja, uma queda brusca no Ibovespa é muito significativa, o regime 2, pelo fato de ter esse parâmetro negativo, não apresenta tal característica. Por fim, nota-se persistência de volatilidade

representada pela significância estatística do termo β em ambos regimes, com maior intensidade no regime 2 da série, o qual teve o parâmetro aumentado cerca de 5%.

No âmbito dos setores do mercado acionário brasileiro, considerando o parâmetro tanto para o primeiro quanto para o segundo regime, observa-se uma similaridade ao mercado acionário brasileiro, visto que à exceção do INDEX em seu primeiro regime, os demais setores apresentam efeito assimetria.

Cabe ressaltar que o UTIL e o IEE tiveram os maiores crescimentos de um regime para o outro nesse parâmetro, 225% e 192% respectivamente, o que acentua os efeitos de choques negativos para o segundo regime nesses setores. Já o IMOB foi o único setor que teve queda no parâmetro do primeiro regime para o segundo.

Ao analisar o comportamento frente os choques passados, ou seja, o parâmetro, apenas o IMOB tem característica que segue a orientação do mercado brasileiro e dos outros setores, o que sugere que este setor responde positivamente a choques negativos na amostra em seu primeiro regime. Entretanto, essa característica não se mantém no segundo regime, sendo que IFNC, IMAT e IMOB têm mudança nesse parâmetro, ocasionando assim uma mudança de resposta a grandes oscilações nas séries de um regime para o outro. Por fim, ao avaliar o parâmetro persistência, IFNC, UTIL e IEE têm o primeiro regime se caracterizando como o mais estável, e por isso diferente do mercado brasileiro.

Cabe ressaltar o alto crescimento do grau de persistência da volatilidade para segundo regime do INDEX, cerca de 280%, o que torna o segundo regime desse setor com volatilidade carregada por muitos períodos até se dissipar.

Apresentadas as características gerais da volatilidade de cada setor do mercado brasileiro, parte-se para análise da dinâmica da volatilidade. Com a finalidade de se avaliar especificamente cada regime, tem-se a Figura 1.

Ao se analisar o mercado brasileiro por meio do IBOV, vê-se os dois regimes bem separados nos períodos, sendo que o primeiro persiste até o meio do ano de 2013 e o segundo segue até o final da série. Nota-se o primeiro regime como mais estável, e o segundo com picos de volatilidade, sendo este fenômeno mais visível nos anos de 2014 e 2015. Esse resultado talvez se justifique pela influência da crise europeia, que segundo Hall (2014) foi mais acentuada ao final do ano 2013.

Além disso, a grande incerteza vivida no Brasil a partir de 2014, com turbulências políticas e consequente impacto dessas sob as variáveis macroeconômicas, a exemplo dos subsequentes rebaixamentos nas notas de risco do país, a perda de valor da moeda e a natural avaria competitiva brasileira no mercado internacional, também podem explicar tamanha diferença entre os regimes.

Ao avaliar os setores individualmente, nota-se que apenas UTIL e IEE têm mais alternância entre os regimes. Já os demais setores têm a característica de maior manutenção dos regimes, fato que torna visível a predominância de cada regime ao longo de cada ano estudado.

O IFNC tem maior predominância do primeiro regime, que é aquele com maior grau de persistência da volatilidade, e ocupa cerca de 80% da série. Esse se mantém do ano de 2015 até o final da amostra. Em comparação ao IBOV, nota-se muita similaridade, fato que encontra viés na literatura. O trabalho de Pereira *et al.* (2017) mostra uma forte correlação entre os dois índices, visto que o IFNC é composto pelas maiores instituições presentes no IBOV.

Já o UTIL é um dos índices com maiores alternâncias entre os regimes. O primeiro regime dessa série é o que mais se mantém na amostra, cerca de 90% da série, sendo esse o de maior persistência na volatilidade. Já o segundo regime é mais volátil e se apresenta em pequenos picos durante a série.

O ICON tem o primeiro regime na maior parte da amostra, cerca de 62% da série. Esse regime é o um dos menos voláteis entre todos os índices, o que confere ao ICON o indicador de menor oscilação e persistência entre todos os setores. Com relação ao segundo regime - o mais volátil - observa-se picos persistentes entre 2014 e 2015, voltando a ocorrer apenas em 2017. Por ser um indicador em que está contido empresas de consumo cíclico, esses resultados podem encontrar explicação na queda de consumo no país entre esses períodos. Segundo Filho (2017), a crise de 2014/2017 da economia brasileira reduziram a capacidade de crescimento da economia e o conseqüente declínio do consumo no país.

Em relação ao IEE, assim como o UTIL, caracteriza-se pela acentuada alternância entre os regimes, sendo que o primeiro é o mais predominante e de volatilidade com maior grau de persistência. Assim como o UTIL, o IEE também tem picos esparsos do segundo regime - o mais volátil - e com pouca incidência ao decorrer do espaço amostral.

O IMAT é composto por dois regimes de alta persistência. No entanto, o primeiro regime, que é o menos volátil, é predominante nessa série (cerca de 78%). Esse regime começa ao final de 2014 e segue até o final da amostra. Já o segundo regime, que é de maior volatilidade condicional entre todos os indicadores estudados, vigora durante todo o ano de 2013 da amostra. Isso pode ser resultado da crescente importação de materiais de construção pelo país, somado à forte demanda do mercado interno.

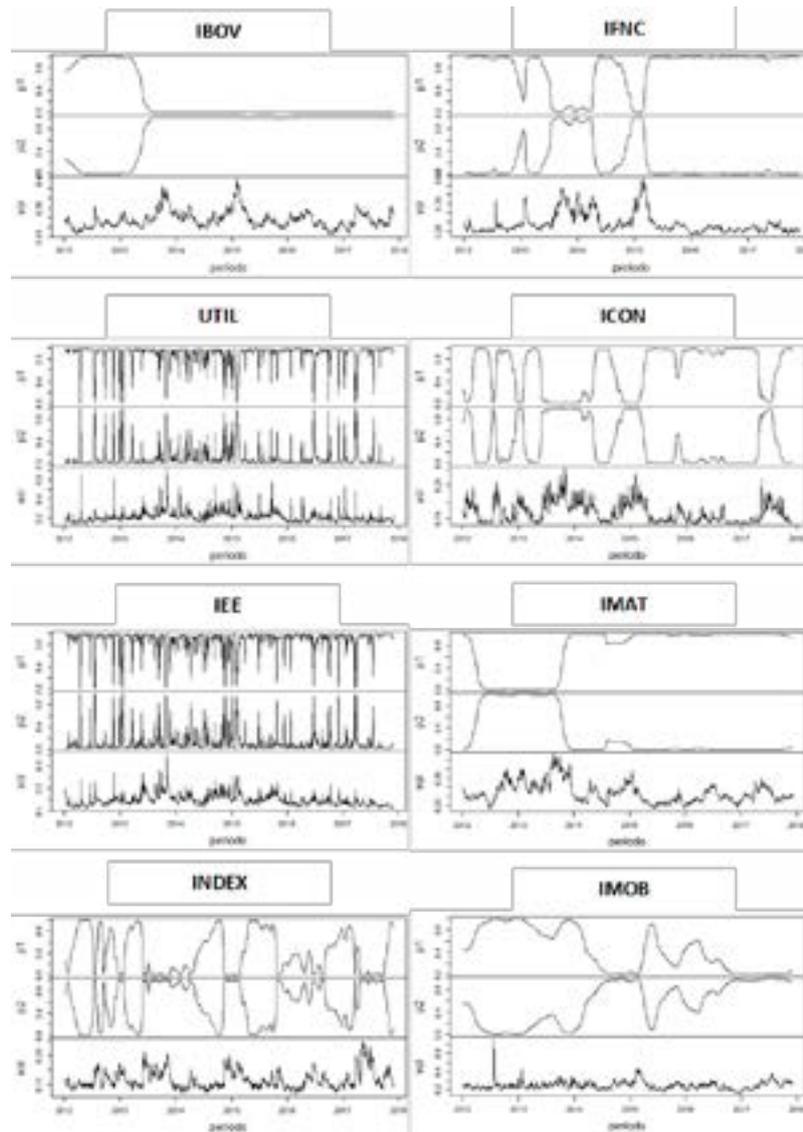
Segundo estudo feito pela FGV Projetos (2014), somente no ano de 2013 o nível de importações de materiais de construção dobrou em relação a 2010 – que era o ano que tinha atingido o recorde em importações desse segmento - o que, somado à crise internacional impactou as empresas que compõem o IMAT, gerando grande oscilação nesse índice.

O INDEX tem dois regimes bem distintos, sendo o primeiro com maior predominância na amostra. Esse regime é um dos menos voláteis e o com menor grau de persistência entre todos os setores analisados. Já o segundo regime, cuja volatilidade é persistente, tem picos que perduram ao longo da série, sendo mais visível entre os anos de 2013, 2015, 2016 e 2017. Esse comportamento pode ser explicado pela grande oscilação e forte queda da moeda brasileira no mercado internacional, o que impacta diretamente a atividade industrial que lida majoritariamente com o câmbio.

Por fim, o IMOB caracteriza-se pela predominância do segundo regime na série, o qual está presente em cerca de 58% da amostra. O primeiro regime é caracterizado pela grande volatilidade condicional, entretanto com um grau de persistência relativamente baixo em relação aos demais setores. Já o segundo regime dessa série é mais volátil e altamente persistente. Devido a essas características, observa-se a presença desse regime em 2014, demorando aproximadamente todo o ano para haver a mudança para o primeiro regime novamente.

O mesmo acontece ao início de 2017, no entanto não houve mudança do segundo regime até o final desse estudo. Dado o que aconteceu anteriormente, espera-se a mudança para o primeiro regime ao início de 2018.

Figura 1 – Regimes de Markov ajustados ao Ibovespa e setores do mercado acionário brasileiro



5 Conclusões

No presente estudo, buscou-se estudar o comportamento da volatilidade dos diferentes setores econômicos da Bolsa de Mercadorias, Valores e Futuros de São Paulo entre os períodos de 2012 e 2017 de maneira dinâmica, por meio de regimes. Assim, utilizou-se o modelo de cadeias de Markov. Observou-se que a maior parte dos setores, bem como o mercado brasileiro, são ausentes de efeito alavancagem. Além disso, houve predomínio de assimetria bem como a persistência de volatilidade para a maior parte das séries.

Com a definição estatística do modelo MRS-EGARCH de dois regimes, foi possível avaliar as características de cada setor. Notou-se uma similaridade entre o IBOV e IFNC, sendo o primeiro regime de ambos caracterizado pela persistência da volatilidade além de ocupar a maior parte da amostra, com maior ênfase de 2014 até o final das observações. Já o segundo regime, que é mais volátil e tem menor persistência em relação ao primeiro regime

tem predominância entre os anos de 2012 a 2013. Essa similaridade pode ser explicada pela composição do IFNC, cujas firmas são muito significativas para o cálculo do IBOV.

Outra similaridade encontrada foi entre UTIL e IEE, com o primeiro regime sendo preponderante em ambos os índices, e eles sendo caracterizados pelas alternâncias entre os dois regimes. Pode-se destacar a influência da crise de 2014 a 2017 na volatilidade do ICON, visto que seus regimes têm uma das maiores diferenças entre as séries estudadas, sendo o primeiro menos persistente e de maior incidência da amostra, e o segundo, com grande volatilidade e persistência.

O IMAT teve a característica de possuir dois regimes com alta persistência de volatilidade. No entanto, o segundo regime dessa série foi um dos de maior volatilidade condicional entre todos os índices estudados. O INDEX, diferentemente do IMOB, caracterizou-se pela presença de dois regimes bem distintos. O primeiro regime, de maior predominância, foi um dos de menor volatilidade condicional e persistência entre as séries estudadas. O segundo regime, cuja volatilidade é persistente, caracterizou-se pelos picos que perduram ao longo da série

Por fim, o IMOB teve a predominância do segundo regime na série. O primeiro regime teve grande volatilidade condicional, mas com baixo grau de persistência, enquanto o segundo regime dessa série foi mais volátil e altamente persistente.

Assim, cumpriu-se a principal motivação desse trabalho, que é o de analisar de maneira dinâmica a volatilidade no mercado brasileiro. Pôde-se inferir que cada setor tem sua característica, e que não necessariamente segue uma tendência estática ao longo do tempo, ou seja, com um único regime. Além disso, foi possível verificar que existem mudanças acentuadas nos regimes de cada índice, e essas informações podem fazer com que se enriqueça o entendimento dos movimentos das séries financeiras.

Destacam-se como principais limitações desse trabalho a ausência de comparação entre diversos modelos de volatilidade, a fim de se verificar aquele com mais robustez às séries. Como sugestões de futuras pesquisas ressalta-se aqui a proposição de estimação de previsão para as séries estudadas, o que pode validar aquele modelo que melhor se ajuste à amostra.

Referências

AKAIKE, H. (1974). "A new look at the Statistical Model Identification". *IEEE Transactions on Automatic Control*. 19(6), 716-723.

ALEXANDER, S, THIERRY, C. & KATERYNA, S. (2009). Volatility Models: from GARCH to Multi-Horizon Cascades. *Documents de travail du Centre d'Economie de la Sorbonne*. n 36 ISSN: 1955-611X.

ALIZADEH, A. H., NOMIKOS, N. K. & POULIASIS, P. K. (2008), A Markov regime switching approach for hedging energy commodities. *Journal of Banking and Finance*. n 32, p 1970-1983.

- ARDIA, D., BLUTEAU, K., BOUDT, K. & CATANIA, L. (2017). "Forecasting Risk with Markov-Switching GARCH models: A Large-Scale Performance Study". 3 January, 2018. Available: <https://ssrn.com/abstract=2918413> or <http://dx.doi.org/10.2139/ssrn.2918413>.
- BAILLIE, R., CHUNG, C. F. & TIESLAU, M. A. (1996). Analyzing inflation by the fractionally integrated ARFIMA-GARCH model. *Journal of applied Econometrics*, 11, p. 23-40.
- BOHL, M. T., SALM, C. A. & WILFLING, B. (2011). Do individual index futures investors destabilize the underlying spot market? *Journal of Futures Markets*. 31, 81-101.
- BOLLERSLEV, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*. 31, 307-328.
- BOLSA DE VALORES, MERCADORIAS E FUTUROS DE SÃO PAULO. (2018). Índices setoriais. 31 Dezembro, 2017. Disponível em: http://www.bmfbovespa.com.br/pt_br/produtos/indices.
- CAI, J. (1994). A Markov model of unconditional variance in ARCH. *Journal of Business and Economic Statistics* 12, 309-316.
- CHLEBUS, M. (2016). EWS-GARCH: New Regime Switching Approach to Forecast Value-at-Risk. [Working paper nº6/2016 (197)]. University of Warsaw, Poland.
- ENGLE, R. F. (1982). Autoregressive conditional heteroskedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*. 50, 987-1007.
- FGV PROJETOS. (2014). Perfil da Cadeia Produtiva da Construção e da Indústria de Materiais e Equipamentos, da Abramat. 11 Janeiro, 2018. Disponível em: <http://www.abramat.org.br/datafiles/publicacoes/materiais-equipamentos2014.pdf>.
- FILHO, F. H. B. (2017). A crise econômica de 2014/2017. *Estudos avançados*. 31, n.89, 51-60.
- GLOSTEN, L. R., JAGANNATHAN, R. & RUNKLE, D. E. (1993). On the relation between expected value and the volatility of the nominal excess return on stocks. *Journal of Finance*. 48, 1779-1801.
- GÜNAY, S. (2015). Markov Regime Switching Generalized Autorregressive Conditional Heteroskedastic Model and Volatility Modeling for Oil Returns. *International Journal of Energy, Economics and Policy*. 5(4), 979-985.
- HAAS, M., STEFAN, M. & MARC S. P. (2004). A new approach to Markov-switching GARCH models. *Journal of Financial Econometrics*. 2, 493-530.
- HAMILTON, J. D. (1988). Rational expectations econometric analysis of changes in regime: An investigation of the term structure of interest rates. *Journal of Economic Dynamics and Control*. 12, 385-423.
- HAMILTON, J. D. (1989). A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica*. 57, 357-384.

- HAMILTON, J. D. & SUSMEL, R. (1994). Autoregressive conditional heteroskedasticity and changes in regime. *Journal of Econometrics*. 64, 307-333.
- HALL, H. (2014). Political Economy Principles in Europe may be changed by the Economic Crisis Governance. 31 December, 2017, Available: http://speri.dept.shef.ac.uk/wp-content/uploads/2013/06/SPERI_Paper_Hacker.pdf.
- HENRY, O. T. (2009). Regime switching in the relationship between equity returns and short-term interest rates in the UK. *Journal of Banking and Finance*. 33, 405-414.
- KLAASSEN, F. (2002). Improving GARCH volatility forecasts with regime-switching GARCH. In *Advances in Markov-Switching Models. Empirical Economics*. 27, 223-254.
- KRITZMAN, M., PAGE, S. & TURKINGTON, D. (2012). Regime shifts: Implications for dynamic strategies. *Financial Analysts Journal*. 68(3), 22-39.
- MARCUCCI, J. (2005). Forecasting stock market volatility with regime-switching GARCH models. *Studies in Nonlinear Dynamics & Econometrics*. 9, 1558-3708.
- NELSON, D. B. (1991). Conditional heteroskedasticity in asset returns: a new approach. *Econometrica*. 59, 347-370.
- PEREIRA, A. P., PALMUTI, C., JÚNIOR, P. S. P., SILVA, S. W. & ALVES, A. P. (2017). A influência dos índices setoriais da bolsa de valores sobre o índice IBOVESPA: uma análise estatística-econométrica no período 2015 e 2016. In: XX SEMEAD Seminários em Administração. ISSN 2177-3866.
- REHER, G. & WILFING, B. (2011). Markov-Switching GARCH models in finance: a unifying framework with an application to the German stock market. Masters dissertation. University of Münster, WWU, Germany.
- SCHWARTZ, G. (1976). Estimating the Dimension of a Model. *The Annals of Statistics*. Vol. 6, No. 2. pp. 461-464.
- WENNSTRÖM, A. (2014). Volatility Forecasting Performance of GARCH type volatility models on Nordic equity indexes. Master of Science. Department of Mathematics. Royal Institute of Technology, KTH, Stockholm, Sweden.
- WILFLING, B. (2009). Volatility regime-switching in European exchange rates prior to monetary unification. *Journal of International Money and Finance*. 28, 240-270.
- ZAKOIAN, J. M. (1994). Threshold heteroscedastic models. *Journal of Economic Dynamics and Control*. 18, 931-955.
- ZHANG, Y., YAO, T. & HE, L. (2015). Forecasting crude oil market volatility: can the Regime Switching GARCH model beat the single-regime GARCH models? 03 January, 2018. Available: https://www.researchgate.net/publication/286301906_Forecasting_crude_oil_market_volatility_can_the_Regime_Switching_GARCH_model_beat_the_singleregime_GARCH_models.

ZHANG, Y. & WANG, J. (2015). Exploring the WTI crude oil price bubble process using the Markov regime switching model. *Physica A: Statistical Mechanics and its Applications*. 421, 377-387.

ZHANG, Y. & ZHANG, L. (2015). Interpreting the crude oil price movements: evidence from the Markov regime switching model. *Applied Energy*. 143, 96-109.