

Relações Entre Correlação Serial e Volatilidade: Existe o Efeito LeBaron no Brasil?

(Relations Between Serial Correlation and Volatility: Is There a LeBaron Effect in Brazil?)

Regis Augusto Ely*

Resumo

Este artigo examina a relação entre correlação serial e volatilidade nos retornos do índice Ibovespa, estendendo a evidência empírica do efeito LeBaron para ordens de correlação serial mais altas. Para a estimação da volatilidade, utilizamos modelos com heteroscedasticidade condicional. Para o cálculo da correlação serial, utilizamos uma estatística de razão de variância onde a defasagem é calculada endogenamente. Os resultados estão de acordo com alguns fatos estilizados da teoria de finanças comportamental e ajudam a explicar alguns fenômenos encontrados na literatura empírica, demonstrando que (i) a correlação serial dos retornos semanais está negativamente relacionada com volatilidade, (ii) essa relação negativa está presente nos retornos diários apenas se utilizarmos correlação serial de primeira ordem, e (iii) a crise de 2008 não intensificou esse efeito para retornos semanais, mas produziu uma relação positiva entre volatilidade e correlação serial para retornos diários.

Palavras-chave: volatilidade; correlação serial; efeito LeBaron.

Códigos JEL: C58; G14; G15.

Submetido em 6 de agosto de 2013. Reformulado em 6 de dezembro de 2013. Aceito em 20 de fevereiro de 2014. Publicado on-line em 2 de junho de 2014. O artigo foi avaliado segundo o processo de duplo anonimato além de ser avaliado pelo editor. Editor responsável: Rodrigo Bueno. O autor agradece a José Guilherme de Lara Resende, Benjamin Miranda Tabak, Otávio Ribeiro de Medeiros, Paulo César Coutinho, José Carneiro da Cunha Oliveira Neto, aos participantes do 13º Encontro Brasileiro de Finanças, bem como um avaliador anônimo pelos comentários e sugestões.

*Departamento de Economia, Universidade Federal de Pelotas (UFPel), Pelotas, RS.
E-mail: regis.ely@ufpel.edu.br

Rev. Bras. Finanças (Online), Rio de Janeiro, Vol. 12, No. 1, March 2014, pp. 13-39
ISSN 1679-0731, ISSN online 1984-5146

©2014 Sociedade Brasileira de Finanças, under a Creative Commons Attribution 3.0 license -
<http://creativecommons.org/licenses/by/3.0>

Abstract

This paper examines the relation between serial correlation and volatility of the Ibovespa index returns and extends the empirical evidence of the LeBaron effect for higher orders of serial correlation. We employ an exponential general autoregressive conditional heteroskedastic model to estimate volatility and an automatic variance ratio statistic to calculate serial correlation. The results support some stylized facts from behavioral finance and help us to explain evidences from empirical studies. We show that (i) serial correlation in weekly returns are negative related with volatility, (ii) this negative relation is found in daily returns only if we use first order serial correlation, and (iii) the effect for weekly returns was not intensified by the 2008 crisis, but a positive relation between volatility and serial correlation for daily returns was identified during that time.

Keywords: volatility; serial correlation; LeBaron effect.

1. Introdução

O estudo das propriedades estatísticas das séries temporais financeiras leva à conclusão de que entre as principais variáveis que definem o comportamento dos retornos acionários estão a correlação serial e a volatilidade, sendo ambas extensivamente examinadas na literatura (Fama & French, 1988, Chordia *et al.*, 2008, Campbell & Hentschel, 1992, Ang *et al.*, 2006).

Em um mercado com eficiência informacional, as mudanças de preços não podem ser previstas, sendo que os preços dos ativos comportam-se como um passeio aleatório, onde a melhor previsão possível é a observação imediatamente anterior (Samuelson, 1965). Nesse caso, podemos demonstrar que os retornos são serialmente não correlacionados. Logo, a correlação serial é uma medida de extrema importância para mensurar a eficiência e a possibilidade de arbitragem em mercados financeiros.

Como a literatura tem demonstrado, retornos acionários tendem a ser pouco previsíveis devido ao fato de apresentarem baixo grau de correlação serial (Pesaran & Timmermann, 1995). Entretanto, a variância condicional dos retornos, ou volatilidade, é altamente previsível, sendo caracterizada pela persistência e por sua distribuição apresentar caudas espessas (Engle, 1982, Liu *et al.*, 1999). Esse fato faz com que a estimação e a previsão da volatilidade sejam instrumentos essenciais para o gerenciamento de risco de portfólios de ativos.

O estudo da relação entre correlação serial e volatilidade pode contribuir para entender a influência da volatilidade no mecanismo de formação de preços. A estimação da correlação serial impõe dificuldades para essa

análise devido ao fato de necessitarmos de observações com a mesma frequência da estimativa da volatilidade. Por isso talvez esse tema não tenha sido tão frequente na literatura, sendo LeBaron (1992) quem primeiramente encontrou uma relação sólida entre essas variáveis, concluindo que as previsões de volatilidade são negativamente relacionadas à correlação serial de primeira ordem, o chamado efeito LeBaron.

Este artigo investiga a ligação entre essas variáveis para o mercado acionário brasileiro utilizando retornos do índice Ibovespa. Primeiramente incluímos um efeito autocorrelação no modelo EGARCH para verificarmos a existência do efeito LeBaron nos retornos deste índice. Em um segundo momento, estendemos as conclusões de LeBaron para ordens mais altas de correlação serial através da utilização de uma estatística de razão de variância onde a defasagem é calculada endogenamente. Para isso, também estimamos a volatilidade através de um modelo autorregressivo generalizado exponencial com heteroscedasticidade condicional (EGARCH), amplamente aplicado para modelar a variância condicional de ativos financeiros (Nelson, 1991). Obtemos as estimativas com o intuito de responder as seguintes perguntas: 1) Existe o efeito LeBaron no mercado acionário brasileiro? 2) A volatilidade afeta significativamente as correlações seriais de ordens mais altas dos retornos do Ibovespa? 3) Quais os efeitos da crise de 2008 nessas relações?

O artigo aborda um tema ainda não estudado pela literatura no Brasil, contribuindo para o entendimento do mecanismo de formação de preços no mercado acionário. Os resultados têm importantes implicações práticas para o gerenciamento de risco de carteiras de ativos, podendo auxiliar na identificação de padrões de previsibilidade através de estratégias que explorem a relação entre as duas medidas estatísticas estudadas, uma vez que a evidência de correlação serial negativa em momentos de alta volatilidade pode indicar o melhor meio de rebalancear as carteiras em momentos críticos do mercado acionário. Do ponto de vista teórico, encontramos relações que dão suporte a modelos teóricos de finanças comportamentais, como o modelo de *feedback trading* de Sentana & Wadhwani (1992), além de identificar a ocorrência de outros fatos estilizados no mercado brasileiro. Do ponto de vista empírico, estendemos os resultados de LeBaron (1992) para o mercado acionário brasileiro e para ordens de correlação serial mais altas. Os resultados também ajudam a explicar o fenômeno encontrado por Bianco *et al.* (2009) em que a volatilidade não esperada está positivamente relacionada com a correlação serial.

O artigo está estruturado em cinco seções. Na seção 2 há uma breve revisão da literatura sobre as contribuições teóricas e empíricas relacionadas à volatilidade e à correlação serial. Na seção 3 descrevemos os dados e elaboramos a metodologia utilizada no trabalho. Os resultados são apresentados na seção 4 e as conclusões na seção 5.

2. Revisão de Literatura

A literatura sobre o comportamento de retornos de ativos em mercados financeiros tem explorado tópicos como reversão à média (Lehmann, 1990, Ferreira & Santa-Clara, 2011), efeito calendário (French, 1980, Doyle & Chen, 2009), heteroscedasticidade condicional (Nelson, 1991, Silvennoinen & Teräsvirta, 2009), estatísticas de razão de variância (Lo & MacKinlay, 1988, Kim, 2009), não-linearidades (Scheinkman & LeBaron, 1989, Corradi *et al.*, 2012), entre outros. Em geral, mercados emergentes tendem a apresentar possibilidades de arbitragem de ganhos maiores do que em mercados desenvolvidos, podendo ser encontradas algumas evidências mais fortes de previsibilidade (Chang *et al.*, 2004).

O principal indicativo da possibilidade de previsão é a existência de correlação serial dos retornos. Para testar essa hipótese, foram construídas estatísticas que exploram algumas propriedades básicas de um passeio aleatório, como razões de variância e testes de Portmanteau. O teste de razão de variância inicialmente proposto por Lo & MacKinlay (1988) e Cochrane (1988) sofreu diversas mudanças com o intuito de melhorar sua potência e poder perante amostras pequenas (Chen & Deo, 2006) e automatizar o processo de escolha das defasagens (Choi, 1999). O mesmo ocorreu com testes de Portmanteau, mais especificamente o teste de autocorrelação de Ljung-Box (Escanciano & Lobato, 2009).

Modelos com heteroscedasticidade condicional surgiram com os trabalhos de Engle (1982) e Bollerslev (1986) com o intuito de explicar a aglomeração dos retornos em torno de algumas poucas observações mais significativas. Uma série de aprimoramentos nos modelos iniciais foram propostos, como os modelos EGARCH (Nelson, 1991), GJR-GARCH (Glosten *et al.*, 1993), TGARCH (Zakoian, 1994), modelos de mudança de regime (Cai, 1994, Hamilton & Susmel, 1994), entre outros. A volatilidade, medida como a variância condicional, passou a ser vista como um processo altamente autorregressivo e com aglomerações.

A relação entre volatilidade e retornos acionários tem sido objeto de investigação na literatura especializada (Ang *et al.*, 2006), sendo a ligação

com a correlação serial primeiramente abordada no modelo de *feedback trading* proposto por Sentana & Wadhwani (1992). Nesse modelo existem dois tipos de investidores: *mean-variance traders* e *feedback traders*. A função de demanda do segundo tipo de investidor é relacionada a retornos passados, sendo ela crescente se os investidores seguem uma estratégia de *feedback* positivo, ou *momentum* (investindo em ações com bons rendimentos passados), e decrescente se eles adotam uma estratégia de *feedback* negativo, ou *contrarian* (investem em ações com baixos retornos no passado). Sentana & Wadhwani (1992) mostraram que no equilíbrio, a correlação serial é uma função decrescente (crescente) da volatilidade se os investidores seguem uma estratégia de *momentum* (*contrarian*).

Na literatura empírica, LeBaron (1992) foi quem primeiro estudou a ligação entre essas variáveis para retornos diários e semanais do mercado acionário nos Estados Unidos. Ele encontrou uma relação negativa entre correlação serial e volatilidade utilizando um modelo autorregressivo exponencial em conjunto com um modelo GARCH para estimação dos retornos (EAR-GARCH), dando suporte empírico ao modelo de *feedback trading*. Sentana & Wadhwani (1992) encontraram resultados semelhantes para dados diários de índices agregados nos Estados Unidos. Koutmos (1997) estendeu esses resultados para outros mercados de países desenvolvidos utilizando uma metodologia similar a de LeBaron. Em trabalhos mais recentes, Venetis & Peel (2005) encontraram relação negativa entre volatilidade e correlação serial em três mercados internacionais, enquanto Chang (2009), utilizando dados a partir de 1998, observou o mesmo resultado entre essas variáveis em Taiwan. Para dados intradiários, Bianco *et al.* (2009) confirmaram o efeito encontrado por LeBaron, apesar de relatarem uma relação positiva da correlação serial com a volatilidade não esperada.

A literatura brasileira ainda carece de estudos que complementem o conhecimento sobre as relações existentes entre as variáveis do mercado financeiro. Mais especificamente, a relação entre volatilidade e correlação serial para ativos do mercado acionário brasileiro é ainda desconhecida, motivando a pesquisa na área.

3. Metodologia

Na seção 3.1 descrevemos os dados amostrais em ambas as frequências diária e semanal. Para estimarmos a correlação serial, utilizamos uma estatística de razão de variância que escolhe a defasagem endogenamente, apresentada na seção 3.2. O modelo com heteroscedasticidade condicional

utilizado na estimação da volatilidade é descrito na seção 3.3. Primeiramente, elaboramos um modelo EGARCH com efeito autocorrelação na seção 3.4, utilizado para testar a existência do efeito LeBaron no mercado acionário brasileiro. Em uma segunda etapa, estudamos as correlações entre as medidas de volatilidade e razão de variância através dos modelos apresentados nas seções 3.5 e 3.6.

3.1 Dados

Utilizamos o índice Ibovespa nominal nas frequências diária e semanal durante o período de fevereiro de 1999 a dezembro de 2011. A escolha do Ibovespa deve-se ao fato de ele ser o mais importante indicador do desempenho médio das cotações do mercado de ações brasileiro. O período de janeiro de 1999 coincide com a flexibilização da política cambial no Brasil, impactando na dinâmica do comportamento do mercado acionário. Por isso foram retirados períodos anteriores a fevereiro de 1999. A inclusão da frequência semanal deve-se ao fato de retornos diários apresentarem ruídos que podem influenciar na análise dos dados. Ao todo são 3.184 observações diárias e 674 semanais.

Os retornos acionários são calculados como:

$$r_t = \ln(P_t/P_{t-1}) = \ln(P_t) - \ln(P_{t-1}), \quad (1)$$

onde P_t é o valor do índice Ibovespa no tempo t e $\ln(\cdot)$ a função logaritmo natural. Na Tabela 1 apresentamos as estatísticas descritivas para os retornos nas frequências diária e semanal do Ibovespa.

Tabela 1

Estatísticas descritivas dos retornos do Ibovespa

	Retornos diários	Retornos semanais
Média	0,00061	0,00287
Desvio-padrão	0,01962	0,04186
$LB(10)$	18,32*	22,57 [†]
$LB^2(10)$	1499,01 [‡]	129,02 [‡]
Phillips-Perron	-56,9382 [‡]	-28,3772 [‡]
Assimetria	-0,099	-0,535
Curtose (Exc.)	3,657	2,842
Jarque-Bera	1780,07 [‡]	259,07 [‡]

Os símbolos [‡], [†] e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Os retornos em ambas as frequências apresentam média positiva mas próxima de zero. A distribuição dos retornos observados é diferente da nor-

mal, sendo negativamente enviesada e leptocúrtica, devido à assimetria negativa e ao excesso de curtose. O teste de Ljung-Box não rejeita a hipótese nula de que os retornos diários não são autocorrelacionados ao nível de 5% de significância, enquanto que para os retornos semanais a hipótese nula é rejeitada ao nível de 1% de significância. Ambas as séries têm comportamento estacionário, pois o teste de Phillips-Perron rejeita a hipótese nula de raiz unitária para retornos diários e semanais. Como indicativo da presença de heteroscedasticidade condicional, os quadrados dos retornos rejeitam a hipótese nula do teste de Ljung-Box em ambas as frequências.

3.2 Razão de variância

Um mercado é eficiente na forma fraca se mudanças de preços não podem ser previstas utilizando-se os preços passados. Estatisticamente, essa definição é incorporada em modelos de passeio aleatório em que a série temporal $\{p_t\}_{t=1}^T$ segue a dinâmica:

$$p_t = \mu + p_{t-1} + \varepsilon_t, \quad (2)$$

onde μ é a média do processo e ε_t um ruído branco não necessariamente normal, que satisfaz $E[\varepsilon_t] = 0$, $E[\varepsilon_t^2] = \sigma^2$ e $E[\varepsilon_t \varepsilon_\tau] = 0$ para todo $t \neq \tau$.

Logo, se o logaritmo natural dos preços seguir um passeio aleatório, os retornos definidos em (1) serão serialmente não correlacionados. Lo & MacKinlay (1988) e Cochrane (1988) demonstraram que nesse caso, a variância dos retornos deve ser uma função linear da defasagem em que eles são calculados, de modo que $Var(p_t - p_{t-k}) = k \times Var(p_t - p_{t-1})$. Com isso, define-se a razão de variância de um passeio aleatório como:

$$VR(k) = \frac{var(r_t(k))/k}{var(r_t)} = 1, \quad \forall k = 1, 2, \dots, T-1. \quad (3)$$

Quando a razão de variância for menor (maior) que um, o processo apresenta reversão (aversão) à média. Por outro lado, quanto maior for o valor de $|VR(k) - 1|$, mais serialmente correlacionado será o processo.

O valor da estimativa de $VR(k)$ depende da defasagem k utilizada, sendo comum na literatura a escolha arbitrária desse coeficiente. Com o intuito de facilitar o cálculo das razões de variância, optamos por uma estimação que escolhe endogenamente o valor da defasagem de acordo com o método para escolha ótima de valores de truncagem desenvolvido por Andrews (1991).

Para a construção desta estatística, utilizamos o fato demonstrado por Cochran (1988) de que o estimador usual de razão de variância é assintoticamente equivalente a 2π vezes o estimador da densidade espectral normalizada na frequência zero, que usa o núcleo de Bartlett. Assim,

$$\hat{V}R(k) \cong 1 + 2 \sum_{i=1}^{k-1} \frac{(k-i)}{k} \hat{\rho}_i \sim 2\pi \frac{f_{\Delta y}(0)}{\hat{\sigma}^2}. \quad (4)$$

Conforme Choi (1999), utilizamos o núcleo espectral quadrático na estimação por apresentar propriedades ótimas¹. Obtemos então a seguinte estimativa da razão de variância:

$$\hat{V}R(k) = 1 + 2 \sum_{i=1}^{T-1} m(i/k) \hat{\rho}(i), \text{ onde} \quad (5)$$

$$m(x) = \frac{25}{12\pi^2 x^2} \left[\frac{\sin(6\pi/5)}{6\pi x/5} - \cos(6\pi x/5) \right], \quad (6)$$

$$\hat{\rho}(i) = \frac{\sum_{t=1}^{T-i} (r_t - \hat{\mu})(r_{t+i} - \hat{\mu})}{\sum_{t=1}^T (r_t - \hat{\mu})^2}, \quad (7)$$

onde $\hat{\mu} = T^{-1} \sum_{t=1}^T r_t$ é a média amostral de r_t , $\hat{\rho}(i)$ é o i -ésimo coeficiente de correlação amostral de r_t , e $m(x)$ é o núcleo espectral quadrático. O valor do coeficiente de defasagem k é escolhido conforme Andrews (1991):

$$\hat{k} = 1.3221(\hat{\alpha}(2)T)^{1/5}, \quad (8)$$

onde $\hat{\alpha}(2)$, no caso de um passeio aleatório, é reduzido a²:

$$\hat{\alpha}(2) = \frac{4\hat{\rho}(1)^2}{(1 - \hat{\rho}(1))^4}, \quad (9)$$

onde $\hat{\rho}(1)$ é o coeficiente de autocorrelação de primeira ordem de r_t .

¹Andrews (1991) demonstra que o núcleo espectral quadrático é ótimo para estimar a densidade espectral na frequência zero.

²Para maiores detalhes, ver equação 6.4 de Andrews (1991).

A razão de variância descrita em (5) apresenta propriedades ótimas para estimação de dados com heteroscedasticidade condicional e não normalidade, sendo utilizada para testar a correlação serial de ativos financeiros em artigos recentes (Kim, 2009, Ely, 2011).

A dificuldade em investigar a relação entre correlação serial e volatilidade consiste em construir uma medida de correlação serial para cada instante t . Alguns trabalhos utilizaram dados intradiários para obter estimativas da correlação serial na frequência diária (Bianco *et al.*, 2009). No nosso caso, adotamos a razão de variância como estimativa de correlação serial para podermos utilizar observações diárias e semanais sobrepostas.

Tendo isso em vista, construímos estimativas da razão de variância dada em (5) para cada bloco sobreposto de 100 observações. A perda das observações iniciais para a construção da primeira estimativa da razão de variância não é significativa para a totalidade da amostra. Por outro lado, 100 é um número razoável de observações para estimação dessa estatística (Kim, 2009), fazendo com que a influência exercida pela observação atual no tempo t seja ainda relevante.

3.3 Volatilidade

Para estimação da volatilidade utilizamos um modelo exponencial generalizado autorregressivo com heteroscedasticidade condicional (EGARCH) proposto por Nelson (1991) e amplamente utilizado para modelar a variância condicional de retornos em mercados financeiros. Em modelos do tipo ARCH, a volatilidade é estimada como um processo autorregressivo. Optamos pelo modelo exponencial pois além do fato da transformação logarítmica relaxar a restrição de não-negatividade aos coeficientes, facilitando a estimação, o modelo reproduz satisfatoriamente o alto grau de assimetria nos retornos acionários.

No artigo, adotamos o modelo EGARCH(1,1) para a estimação da volatilidade dos retornos do índice Ibovespa na frequência diária e semanal. Essa especificação é a mais parcimoniosa e consegue eliminar completamente a correlação da variância condicional das séries temporais, conforme será demonstrado na seção dos resultados. Assim, a série de retornos $\{r_t\}_{t=1}^T$ é estimada como:

$$\begin{aligned}
r_t &= \mu + \varepsilon_t, \text{ com } \varepsilon_t | I_{t-1} \sim GED(0, h_t, v), \\
\ln(h_t) &= \omega + \alpha \left(\left| \frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}} \right| - E \left[\left| \frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}} \right| \right] \right) \\
&\quad + \gamma \frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}} + \beta \ln(h_{t-1}),
\end{aligned} \tag{10}$$

onde μ é a média dos retornos, I_{t-1} é o conjunto informacional até o tempo $t - 1$ e ε_t é o resíduo do modelo, que segue a distribuição de erros generalizada, com variância condicional h_t . Na equação (10), o termo $\frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}}$ corresponde ao resíduo padronizado do modelo, ω define a média e β a persistência da variância condicional. Os coeficientes α e γ capturam o efeito tamanho e o efeito sinal, respectivamente. O primeiro mede o aumento da volatilidade causado pelo choque, independentemente da direção do mesmo. O segundo mede a assimetria dos choques na volatilidade, sendo que choques negativos terão importância maior que choques positivos caso este coeficiente seja estatisticamente significativo e menor que zero.

A importância relativa da assimetria para o conjunto dos dados é estimada pelo termo $|-1 + \gamma|/(1 + \gamma)$. Quanto mais negativo for o coeficiente γ , maior será essa razão, indicando que choques negativos têm maiores impactos na volatilidade.

Tendo em vista o excesso de curtose presente nos retornos, conforme indica a Tabela 1, utilizamos a distribuição de erros generalizada $GED(0, h_t, v)$ para o resíduo ε_t do modelo descrito em (10), sendo v o parâmetro que mede a espessura da cauda da distribuição. A densidade da distribuição GED com média zero e variância unitária é descrita por:

$$f(\varepsilon; v) = \frac{v \exp[-(1/2)|\varepsilon/\lambda|^v]}{\lambda 2^{(1+1/v)} \Gamma(1/v)} \text{ com } -\infty < \varepsilon < \infty, 0 < v < \infty, \tag{11}$$

onde $\Gamma(\cdot)$ é a função gama e $\lambda = [2^{(-2/v)} \Gamma(1/v) / \Gamma(3/v)]^{1/2}$. Quando $v = 2$ obtemos a distribuição normal, quando $v < 2$ a distribuição apresenta caudas mais espessas do que a normal, e se $v = 1$, ela degenerará para a distribuição de Laplace.

Para estimar os parâmetros devemos maximizar a função de log-verossimilhança do modelo:

$$L_t = \ln\left(\frac{v}{\lambda}\right) - 0,5 \left| \frac{\varepsilon_t}{h_t^{1/2}\lambda} \right|^v - \left(1 + \frac{1}{v}\right) \ln 2 - \ln \Gamma\left(\frac{1}{v}\right). \quad (12)$$

Os coeficientes que maximizam a função acima são os parâmetros estimados do modelo, calculados através de métodos numéricos recursivos (algoritmo BFGS - Broyden-Fletcher-Goldfarb-Shanno). São utilizados erros padrão robustos de White (1982), comumente aplicados na estimação de modelos GARCH para correção da heteroscedasticidade presente nos resíduos.

3.4 Modelo EGARCH com efeito autocorrelação

LeBaron (1992) encontrou uma relação negativa entre correlação serial de primeira ordem e volatilidade nos retornos do mercado acionário americano. Para inferirmos sobre a existência do efeito LeBaron no mercado acionário brasileiro, estimamos um modelo AR(1)-EGARCH(1,1) onde o coeficiente autorregressivo é influenciado pela volatilidade:

$$r_t = \mu + \rho_1 h_t^{1/2} r_{t-1} + \varepsilon_t, \text{ com } \varepsilon_t | I_{t-1} \sim GED(0, h_t, v), \quad (13)$$

$$\ln(h_t) = \omega + \alpha \left(\left| \frac{\varepsilon_{t-1}}{\sqrt{h_t}} \right| - E \left[\left| \frac{\varepsilon_{t-1}}{\sqrt{h_t}} \right| \right] \right) + \gamma \frac{\varepsilon_{t-1}}{\sqrt{h_t}} + \beta \ln(h_{t-1}). \quad (14)$$

As variáveis são definidas conforme a seção 3.3, com exceção do coeficiente ρ_1 , que mede o impacto da volatilidade na autocorrelação de primeira ordem dos retornos. Esse fato pode ser observado multiplicando-se a equação (13) por r_{t-1} e aplicando o operador de expectativas condicional à informação disponível em $t - 1$. A estimação é conduzida de maneira semelhante ao modelo (10). Note que um valor negativo do coeficiente ρ_1 implica na existência do efeito LeBaron, dando suporte ao modelo de *feedback trading* de Sentana & Wadhwani (1992).

3.5 Modelo autorregressivo com variável exógena

O modelo da seção anterior apenas considera a correlação serial de primeira ordem. A medida utilizada na seção 3.2 considera ordens mais altas de correlação serial, calculando endogenamente uma defasagem ótima. Uma vez obtidas as estimativas para a razão de variância e a volatilidade, podemos utilizá-las para mensurar as relações existentes entre essas variáveis. Para verificar se a volatilidade fornece alguma informação adicional

que ajuda a prever a correlação serial dos retornos no mercado acionário brasileiro, utilizamos regressões onde a variável dependente é a razão de variância e a variável explicativa é a volatilidade.

A série das razões de variância, como será demonstrado, apresenta alto grau de persistência devido à utilização de observações sobrepostas e pela peculiaridade dessa estatística. Assim, devemos remover a influência das observações anteriores incluindo coeficientes autorregressivos. Para isso utilizamos um modelo autorregressivo com variável exógena, ARX(p), dado por:

$$VR(k)_t = \alpha_0 + \sum_{i=1}^p \alpha_i VR(k)_{t-i} + \beta h_t + \varepsilon_t, \quad (15)$$

onde os coeficientes α_i medem a persistência da razão de variância, β a relação entre correlação serial e volatilidade, e ε_t corresponde aos resíduos do modelo, que seguem uma distribuição normal com média zero e variância σ^2 .

A estimação é realizada pelo método da máxima verossimilhança exata, através da maximização da função de log-verossimilhança:

$$L_t = -0,5T \ln(2\pi) - 0,5T \ln(\sigma^2) - 0,5 \sum_{t=1}^T \left[\frac{\varepsilon_t^2}{\sigma^2} \right]. \quad (16)$$

Neste modelo são utilizados erros padrão de Newey-West por serem robustos na presença de heteroscedasticidade, propriedade característica de dados financeiros. O valor da defasagem p é escolhido com base nos critérios de informação de Akaike e Hannan-Quinn, descritos respectivamente por:

$$AIC = \left(\frac{2T}{T-k-1} \right) k - 2 \ln(L_{max}), \quad (17)$$

$$HQC = 2 \ln(\ln(T))k - 2 \ln(L_{max}), \quad (18)$$

onde T é o tamanho da amostra, k é o número de parâmetros a serem estimados e L_{max} é o valor máximo da função de log-verossimilhança encontrado na etapa da estimação.

O critério de informação Bayesiano não foi utilizado pois penaliza modelos com número elevado de coeficientes, podendo selecionar modelos que não eliminem completamente a persistência das razões de variância. Para contornar o problema do excesso de parâmetros, definimos o grau máximo de defasagens como cinco. A análise dos critérios de informação e seleção das defasagens é realizada na seção 4.2, bem como o cálculo dos coeficientes para as regressões estimadas.

3.6 Modelo com inclusão de *dummy* para a crise

Para avaliarmos o impacto da crise de 2008 na relação entre volatilidade e correlação serial, incluímos *dummies* de intercepto e declividade no modelo exposto na seção anterior. Assim, temos a seguinte regressão:

$$VR(k)_t = \alpha_0 + \sum_{i=1}^p \alpha_i VR(k)_{t-i} + \beta h_t + \delta_1 D_t + \delta_2 D_t h_t + \varepsilon_t, \quad (19)$$

onde os parâmetros δ_1 e δ_2 são os coeficientes das *dummies* de intercepto e de declividade, respectivamente. A variável D_t possui valor um em períodos que correspondem a crise, e zero caso contrário.

Para definirmos o período que abrange o começo e o fim da crise, utilizamos a metodologia de Johnson & Mitton (2003) que se baseia em critérios subjetivos como notícias e eventos políticos, econômicos e financeiros. Assim, o início da crise corresponderá ao mês de julho de 2008, dada a queda subsequente de mais de 40% no índice Ibovespa. A recuperação no valor do índice começou em abril de 2009, por isso definimos o mês de março de 2009 como o fim da crise.

4. Resultados

Os resultados encontrados por LeBaron (1992) são válidos apenas para correlação serial de primeira ordem. Para verificar se esse efeito existe no mercado acionário brasileiro, utilizamos o modelo EGARCH com efeito autocorrelação descrito na metodologia. A seção 4.1 apresenta os resultados obtidos com esse modelo.

Na seção 4.2 analisamos se o efeito LeBaron está presente quando consideramos ordens de correlação serial mais altas. Para isso, estimamos as volatilidades e as razões de variância com defasagem endógena, que são nossas medidas de correlação serial, e então utilizamos modelos autoregressivos com variável exógena para identificar as relações entre essas duas

variáveis. Vários testes são conduzidos na seção 4.3 para checar a robustez dos resultados obtidos.

4.1 Efeito LeBaron

Para estimar o efeito LeBaron, utilizamos o modelo AR(1)-EGARCH(1,1) com efeito autocorrelação, dado pelas equações (13) e (14). Os resultados da Tabela 2 mostram que o coeficiente ρ_1 é negativo e estatisticamente significativo ao nível de 5% para ambos os retornos diários e semanais, apesar de ele apresentar uma maior magnitude para retornos semanais.

Tabela 2

Modelo AR(1)-EGARCH(1,1) com efeito autocorrelação

Painel A: Estimativa dos parâmetros				
	Retornos diários		Retornos semanais	
Coefficientes	Valor estimado	Razão t	Valor estimado	Razão t
μ	0,000736	2,5930 [†]	0,004636	3,1423 [†]
ρ_1	-0,173007	-2,2918 [†]	-2,093510	-2,4902 [†]
ω	-0,234240	-3,4292 [‡]	-0,341129	-1,9900 [†]
α	0,145340	6,6590 [‡]	0,111156	2,7868 [‡]
β	0,971074	113,9494 [‡]	0,947959	35,9383 [‡]
γ	-0,075748	-4,7549 [‡]	-0,076788	-3,0627 [‡]
ν	1,608170	26,3183 [‡]	1,547218	12,6749 [‡]
Painel B: Diagnósticos dos resíduos do modelo				
	Retornos diários		Retornos semanais	
Testes	Valor	P-valor	Valor	P-valor
LB(10)	8,832	0,5481	10,210	0,4222
LB(15)	14,043	0,5223	13,010	0,6018
$LB^2(10)$	7,648	0,6632	3,739	0,9584
$LB^2(15)$	15,365	0,4255	7,340	0,9475

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Os valores em parênteses são as razões t com erros robustos baseados em White (1982).

Conforme discutido na seção 3.4, o coeficiente ρ_1 mede o impacto linear da variância condicional na correlação serial de primeira ordem. Assim, o valor negativo encontrado para este coeficiente implica que momentos de alta volatilidade estão associados a autocorrelações de primeira ordem mais baixas, tanto para retornos diários como para semanais. Esse resultado está de acordo com o encontrado por LeBaron (1992).

4.2 Relação entre as razões de variância e a volatilidade

Para estendermos as evidências do efeito LeBaron para ordens de correlação serial mais altas, primeiro construímos as razões de variância dadas pela equação (5) utilizando observações sobrepostas de 100 períodos. As estatísticas descritivas das razões de variância para ambas as frequências estão resumidas no Painel A da Tabela 3. Na frequência diária, as razões de variância têm média aproximadamente um, apresentam autocorrelação devido à rejeição da hipótese nula do teste de Ljung-Box, e distanciam-se da distribuição normal, com excesso de curtose e enviesamento positivo. Na frequência semanal, a média é menor que um e a série é autocorrelacionada mas próxima da distribuição normal. O Painel B indica o grau ótimo de defasagem autorregressiva para ambas as séries de acordo com os critérios de Akaike e Hannan-Quinn. Devemos incluir cinco defasagens das razões de variância diárias e semanais nas regressões para remover as influências de observações passadas.

Tabela 3

Estatísticas descritivas das razões de variância

Painel A: Estatísticas descritivas				
	VR diária		VR semanal	
Média	1,0055		0,8919	
Desvio-padrão	0,0978		0,0656	
$LB(10)$	24208,04 [‡]		2849,23 [‡]	
Assimetria	0,6812		-0,1904	
Curtose (Exc.)	1,5847		-0,2171	
Jarque-Bera	561,427 [‡]		4,604	
Painel B: Critérios de informação para defasagem AR				
Defasagens	Akaike	Hannan-Quinn	Akaike	Hannan-Quinn
1	-4,774922	-4,773514	-4,662729	-4,656779
2	-4,779276	-4,777165	-4,676132	-4,667208
3	-4,793615	-4,790801	-4,680009	-4,668111
4	-4,794669	-4,791151	-4,685990	-4,671117
5	-4,801143**	-4,796921**	-4,689137**	-4,671289**

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Os valores indicados por ** são as defasagens escolhidas pelo respectivo critério.

Para estimação da volatilidade, utilizamos o modelo EGARCH(1,1) dado pela equação (10) e incluímos um componente autorregressivo nos retornos semanais para remover a autocorrelação indicada na Tabela 1. Os resultados da estimação estão na Tabela 4.

Tabela 4

Estimação da volatilidade para retornos diários e semanais

Painel A: Estimativa dos parâmetros				
	Retornos diários		Retornos semanais	
Coeficientes	Valor estimado	Razão t	Valor estimado	Razão t
μ	0,000726	2,5687 [†]	0,004507	2,7186 [‡]
ϕ_1	-	-	-0,080688	-2,3795 [†]
ω	-0,233655	-3,0807 [‡]	-0,342251	-2,2868 [†]
α	0,145044	6,4761 [‡]	0,113377	2,9445 [‡]
β	0,971144	102,6579 [‡]	0,947764	40,7744 [‡]
γ	-0,076000	-4,3962 [‡]	-0,074743	-2,2931 [†]
ν	1,609744	26,2027 [‡]	1,549785	10,7981 [‡]
Painel B: Diagnósticos do modelo				
	Retornos diários		Retornos semanais	
Testes	Valor	P-valor	Valor	P-valor
LB(15)	13,520	0,5622	12,920	0,5330
$LB^2(15)$	13,868	0,5356	8,214	0,8779

Os símbolos [‡], [†] e * denotam significância ao nível de 1%, 5% e 10%, respectivamente. São utilizados erros robustos baseados em White (1982).

Os retornos diários e semanais do Ibovespa apresentam assimetria, como indicado pelos coeficientes γ . Assim, choques negativos impactam mais a volatilidade do que choques positivos. A importância relativa da assimetria é mensurada pelo coeficiente $|-1 + \gamma|/(1 + \gamma)$, igual a 1,1645 para retornos diários e 1,1616 para retornos semanais. Em ambas as frequências, a variância condicional apresenta alta persistência, sendo as estimativas dos coeficientes β perto de um. Os valores estimados de ν são menores do que dois, caracterizando a presença de caudas mais espessas na distribuição dos resíduos. Por fim, o coeficiente ϕ_1 é negativo para retornos semanais, dando mais evidências da presença de reversão à média nessa frequência. Estes resultados são consistentes com as evidências da literatura para retornos acionários (Liu *et al.*, 1999).

O Painel B da Tabela 4 mostra os valores das estatísticas de Ljung-Box para os resíduos e o quadrado dos resíduos dos modelos estimados. Podemos observar que para ambos os retornos diários e semanais, os modelos eliminam a autocorrelação e a heteroscedasticidade condicional, visto que o teste de Ljung-Box não rejeita a hipótese nula de que os resíduos e o quadrado dos resíduos não são autocorrelacionados.

Na Figura 1 podemos observar o comportamento das razões de variância e da volatilidade para retornos diários e semanais do índice Ibovespa. Os

fatos estilizados na Tabela 3 podem ser observados nos gráficos das razões de variância. Na frequência diária observamos uma concentração dos valores em torno de um, indicando um baixo nível de correlação serial, enquanto que na frequência semanal os valores estão consistentemente abaixo de um, devido a presença de reversão à média, já observada na Tabela 1. Outra característica que podemos observar é a alta persistência destas séries em relação a seus valores passados, visto que movimentos bruscos não desaparecem rapidamente.




Figura 1

Razões de variância e volatilidade diárias e semanais

O comportamento da volatilidade diária e semanal mostra a ocorrência de observações extremas em períodos críticos, como o estouro da bolha da Internet em 2000, as eleições de 2002 e a crise financeira de 2008. A Figura 1 nos permite identificar uma possível relação entre a volatilidade e a razão de variância. Com exceção da crise de 2008, momentos de alta volatilidade parecem estar associados a valores menores da razão de variância. A relação é mais clara para retornos semanais.

Para estudar a relação entre volatilidade e correlação serial de ordens mais altas, utilizamos as medidas de razão de variância e volatilidade construídas acima. A relação é estudada através de regressões onde a razão de variância é a variável dependente e a variância condicional é a variável ex-

plicativa. A regressão 1 da Tabela 5 aponta para uma relação positiva entre essas variáveis na frequência diária, porém o modelo está mal especificado, devido ao alto grau de correlação dos resíduos, de acordo com o teste de Ljung-Box.

Tabela 5

Regressões da razão de variância com a volatilidade para retornos diários

Painel A: Estimativa dos parâmetros			
Coeficientes	Regressão 1	Regressão 2	Regressão 3
α_0	0,9922 (132, 70 [‡])	0,0217 (4, 31 [‡])	0,0222 (4, 36 [‡])
α_1	-	1,0424 (24, 46 [‡])	1,0397 (24, 96 [‡])
α_2	-	-0,1960 (-3, 13 [‡])	-0,1951 (-3, 16 [‡])
α_3	-	0,0947 (3, 00 [‡])	0,0957 (3, 02 [‡])
α_4	-	-0,0467 (-1,59)	-0,0467 (-1,59)
α_5	-	0,0847 (3, 82 [‡])	0,0871 (3, 93 [‡])
β	36,2093 (2, 59 [‡])	-1,9019 (-0,91)	-8,5297 (-1,95*)
δ_1	-	-	-0,0035 (-1,18)
δ_2	-	-	9,6412 (2, 00 [‡])
Painel B: Diagnósticos dos resíduos do modelo			
$LB(10)$	24003, 45 [‡]	10,4550	10,2836
Jarque-Bera	204, 87 [‡]	5604, 32 [‡]	5364, 57 [‡]
R^2 ajustado	0,0110	0,9498	0,9499

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Os valores em parênteses são as razões t com erros robustos de Newey-West (HAC).

Para corrigir esse problema, estimamos o modelo ARX(p) descrito na equação (15), incluindo cinco defasagens das razões de variância, conforme os critérios de Akaike e Hannan-Quinn. A regressão 2 encontra uma relação negativa expressa pelo coeficiente β , entretanto, ela não é significativa para retornos diários.

Na terceira regressão, incluímos *dummies* de intercepto e declividade no modelo para estimar a influência da crise de 2008 na relação entre essas variáveis. Vemos então que o coeficiente β passa a ser significativo ao nível de 10%, e aumenta muito em magnitude. Por outro lado, o coeficiente da *dummy* de declividade é positivo e significativo ao nível de 5%, sendo maior em módulo do que β .

Assim, encontramos uma relação negativa mais forte e significativa entre volatilidade e correlação serial para retornos diários se desconsiderarmos o período da crise. Durante a crise, o sinal da relação inverte, devido a existência de correlação positiva entre retornos diários nesse período

(efeito manada), fazendo com que a volatilidade esteja associada a razões de variância maiores (correlação serial positiva). Essa evidência sugere uma explicação para o fenômeno encontrando por Bianco *et al.* (2009), de que a relação entre volatilidade não esperada e correlação serial é positiva. Isso seria explicado pelo fato de a volatilidade não esperada estar associada a períodos de crise, onde há preponderância de correlação serial positiva, devido ao comportamento de manada.

Os resultados encontrados na literatura evidenciaram uma relação negativa entre as duas variáveis (LeBaron, 1992, Venetis & Peel, 2005). Para o caso brasileiro, ao incluirmos correlações de ordens maiores, os retornos diários do Ibovespa nos indicam que essa relação negativa existe mas é pouco significativa. Ao controlarmos os efeitos da crise, encontramos um coeficiente β de maior magnitude e significância, indicando que a correlação serial positiva gerada em momentos críticos do mercado acionário tende a mitigar a relação negativa entre volatilidade e correlação serial. Para demonstrar se este é o caso, examinamos os dados na frequência semanal, que apresentam menor ocorrência de correlação serial positiva, conforme a Tabela 3 e a Figura 1.

Para retornos semanais, a regressão 1 da Tabela 6 também está mal especificada. Porém, ao incluirmos as defasagens das razões de variância na regressão 2, encontramos uma relação negativa significativa entre correlação serial e volatilidade.

Tabela 6

Regressões da razão de variância com a volatilidade para retornos semanais

Painel A: Estimativa dos parâmetros			
Coeficientes	Regressão 1	Regressão 2	Regressão 3
α_0	0,9081 (61, 78 [‡])	0,0704 (3, 85 [‡])	0,0645 (3, 62 [‡])
α_1	-	1,0641 (13, 41 [‡])	1,0668 (13, 06 [‡])
α_2	-	-0.1993 (-1,69*)	-0,1979 (-1,68*)
α_3	-	-0.03235 (-0,67)	-0,0301 (-0,61)
α_4	-	0,1829 (1,51)	0,1817 (1,49)
α_5	-	-0,0880 (-0,95)	-0,0856 (-0,94)
β	-9,7989 (-1,23)	-3,4661 (-3, 01 [‡])	-4,2660 (-2, 90 [‡])
δ_1	-	-	0,0140 (0,86)
δ_2	-	-	-2,0031 (-0,54)
Painel B: Diagnósticos dos resíduos do modelo			
$LB(10)$	2701.56 [‡]	9,3169	10,0685
Jarque-Bera	2,67	510, 19 [‡]	503, 19 [‡]
R^2 ajustado	0,0134	0,8781	0,8783

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Os valores em parênteses são as razões t com erros robustos de Newey-West (HAC).

Ao incluirmos as *dummies* para avaliar os efeitos da crise de 2008 não obtemos significância do parâmetro δ_2 , indicando que a crise não intensificou essa relação para retornos semanais do Ibovespa.

Os resultados encontrados para o Brasil aproximam-se da literatura para outros mercados internacionais (Koutmos, 1997, Venetis & Peel, 2005, Bianco *et al.*, 2009). Porém, ao analisarmos correlações seriais de ordens maiores, concluímos que a relação negativa entre volatilidade e correlação serial para o índice Ibovespa não desaparece, sendo mais evidente em retornos semanais. Este resultado diverge dos encontrados por LeBaron (1992), onde a série de retornos semanais do índice *Standard & Poor's* apresenta evidência mais fraca desta relação do que a série diária. Parte dessa diferença é explicada pelo fato de retornos semanais do Ibovespa apresentarem maior tendência de reversão à média. Por outro lado, a relação para retornos diários torna-se mais evidente quando controlamos a influência da crise de 2008 nos dados, sugerindo que períodos críticos tendem a mitigar essa relação para retornos em frequências mais altas.

As evidências demonstram que o efeito LeBaron é válido não só para a correlação serial de primeira ordem, pois a volatilidade impacta negativamente a correlação serial de ordens mais altas. A questão teórica da causa

dessa relação em mercados acionários ainda não foi devidamente explicada. As evidências sugerem algumas conexões com a teoria de finanças e finanças comportamentais. Mais especificamente, o fato de períodos de alta volatilidade gerarem tendências de reversão à média pode estar associado a tópicos como *overreaction* dos agentes, acumulação de notícias, em que os agentes não reagem até terem informações suficientes, efeito manada, entre outros.

Estatísticas de razão de variância são extensamente utilizadas na literatura para medir a eficiência de mercados financeiros na forma fraca (Charles & Darné, 2009). O fato de períodos de alta volatilidade estarem associados à correlação serial negativa dos retornos pode ser uma evidência de ineficiência na precificação. Isso nos indica uma possível previsibilidade de retornos acionários nesses períodos de alta volatilidade. Mais ainda, essa previsibilidade é no sentido de reversão à média, sendo que um possível rebalanceamento de portfólio no sentido contrário ao movimento do mercado em períodos de grande volatilidade poderia gerar ganhos extraordinários.

O estudo de retornos anormais obtidos por estratégias do tipo *contrarian* já foi realizado na literatura especializada, porém as evidências apresentadas neste trabalho nos indicam que esta estratégia poderia ser melhor sucedida se aplicada principalmente em períodos de alta volatilidade. O cálculo dos potenciais ganhos de uma estratégia desse tipo, considerando os custos de transação, não é o escopo do artigo, apesar de ser um tópico importante para pesquisas futuras.

4.3 Testes de robustez

Foram realizados alguns testes para verificar a robustez dos resultados das regressões nas Tabelas 5 e 6. Primeiro utilizamos valores diferentes para o tamanho dos blocos nas estatísticas de razão de variância. Depois estimamos as regressões com diferentes defasagens autorregressivas para as razões de variância. Por fim, utilizamos um modelo alternativo para estimar a volatilidade.

Para verificar se a utilização de blocos com apenas 100 observações pode causar distorções nas estimativas da razão de variância de modo a mudar a significância das regressões, estimamos esta estatística com blocos de 200 e 300 observações. Em ambos os casos, a perda de 100 e 200 observações em relação à estatística anterior foi compensada eliminando estas observações da estatística original. Os resultados indicam que não há distorção significativa, pois o sinal e a significância dos coeficientes

permanecem inalterados. Utilizando 200 observações, a diferença na magnitude do coeficiente β na segunda regressão para retornos diários foi $-0,3453$ e para retornos semanais foi $-1,0341$. Com blocos de 300 observações, as diferenças foram $0,5619$ e $0,5912$, respectivamente.

Outra possível fonte de distorções é a seleção da defasagem no modelo $ARX(p)$. Ao incluir um menor número de coeficientes autorregressivos da razão de variância nas regressões das Tabelas 5 e 6 os resultados não foram afetados significativamente, entretanto, os resíduos da regressão passam a ser correlacionados, indicando uma má especificação do modelo. Os resultados demonstram que o menor número de coeficientes autorregressivos que elimina completamente a correlação dos resíduos da regressão é cinco. Esse resultado foi o mesmo encontrado por Bianco *et al.* (2009) para dados intradiários do mercado acionário americano, onde os autores utilizaram regressões semelhantes de uma estatística de razão de variância com a volatilidade.

A mudança na escolha do modelo EGARCH para estimar a volatilidade pode gerar resultados distintos. Para verificarmos se há diferenças significativas, estimamos a variância condicional através de um modelo GJR-GARCH e então calculamos novamente a regressão 2 das tabelas 5 e 6. O coeficiente β para retornos diários continuou não significativo, mudando de $-1,9019$ para $-2,0215$. Para retornos semanais, o coeficiente continuou significativo ao nível de 1%, mudando de $-3,4661$ para $-2,7161$.

5. Conclusão

Este artigo investigou a relação entre correlação serial e volatilidade no mercado acionário brasileiro com dados de retornos diários e semanais do Ibovespa. Primeiramente utilizamos um modelo EGARCH com efeito autocorrelação descrito nas equações (13) e (14) para verificar a existência do efeito LeBaron. Em um segundo momento, estimamos a volatilidade através de um modelo EGARCH e a correlação serial através de uma medida de razão de variância que calcula endogenamente a defasagem dos retornos. Então analisamos a relação entre as duas variáveis através de regressões onde a razão de variância é a variável dependente, verificando assim a existência do efeito LeBaron para ordens de autocorrelação mais altas. Utilizamos também *dummies* para avaliar os efeitos da crise de 2008 nessa relação.

Os resultados demonstram a existência do efeito LeBaron para retornos do Ibovespa nas frequências diárias e semanais. Ao utilizarmos as me-

didadas que incorporam autocorrelações de ordens mais altas, encontramos que a volatilidade afeta negativamente a correlação serial dos retornos na frequência semanal, tendo o efeito menor intensidade para retornos diários. Os efeitos da crise de 2008 nessa relação não são significativos para retornos semanais, mas acabaram invertendo o sinal da relação para retornos diários devido a existência de correlação serial positiva (efeito manada) nas observações. Essa evidência corrobora o resultado de Bianco *et al.* (2009), que encontrou relação positiva entre volatilidade não esperada e correlação serial no mercado acionário americano.

As evidências encontradas sugerem novas questões empíricas e teóricas. O aumento da volatilidade não só induz momentos de reversão à média, mas esse efeito se estende para outros períodos, sendo mais persistente do que o esperado. Por um lado, temos poucas respostas sobre a exata natureza da relação entre volatilidade e correlação serial, visto que os resultados podem ser reflexos de diversas outras fricções existentes no mercado acionário. Esta e outras evidências de previsibilidade podem ser diferentes sintomas de uma mesma doença, o que levanta a questão teórica de como explicar estes resultados.

LeBaron (1992) descarta a possibilidade destes resultados serem reflexo de problemas de *nontrading* devido a relação negativa deste efeito com o volume negociado. *Nontrading* ocorre quando ações não são negociadas no final do dia, gerando correlação positiva dos retornos, pois as últimas informações serão incorporadas apenas no próximo período. Como há uma relação positiva entre volume e volatilidade, então caso houvesse *nontrading*, as correlações seriais seriam maiores em períodos de baixa volatilidade.

Por outro lado, a teoria de finanças comportamentais tem demonstrado que padrões de reversão à média nos retornos podem ser explicados pela existência de *overreaction* por parte dos agentes (Forbes, 1996). É natural pensar que tais momentos coincidam com períodos de alta volatilidade, explicando a relação negativa com a correlação serial. A relação é inversa durante a crise pois observamos um efeito manada por parte dos investidores, de modo que o aumento da volatilidade é associado à correlação serial positiva dos retornos.

Este artigo contribui para a literatura ao abordar relações ainda não estudadas no mercado acionário brasileiro. Também estendemos a análise empírica de LeBaron (1992) utilizando métodos para estimar a correlação serial de ordens mais altas e assim estudar o efeito da volatilidade nessa

variável. Dessa forma, os resultados podem ajudar a explicar alguns fenômenos encontrados na literatura para o mercado acionário americano.

Os resultados têm importantes implicações práticas, uma vez que existe a possibilidade de explorarmos a relação entre volatilidade e reversão à média nos retornos acionários. Estas evidências poderiam ser utilizadas para construção de carteiras, utilizando por exemplo uma estratégia do tipo *contrarian* em períodos de alta volatilidade. Pesquisas futuras podem ajudar a responder até que ponto estas estratégias podem gerar resultados superiores à média do mercado.

As relações discutidas neste artigo ainda precisam ser mais investigadas para podermos explicá-las através da teoria de finanças. Pesquisas futuras devem averiguar até que ponto a relação aqui encontrada está relacionada com outras evidências de previsibilidade de retornos, ou então utilizar modelos não lineares que esclareçam melhor alguns aspectos dos dados.

Referências

- Andrews, Donald W. K. 1991. Heteroskedasticity and Autocorrelation Consistent Covariance Matrix Estimation. *Econometrica*, **59**(3), 817–858.
- Ang, Andrew, Hodrick, Robert J., Xing, Yuhang, & Zhang, Xiaoyan. 2006. The Cross-Section of Volatility and Expected Returns. *The Journal of Finance*, **61**(1), 259–299.
- Bianco, Simone, Corsi, Fulvio, & Renò, Roberto. 2009. Intraday LeBaron effects. *Proceedings of the National Academy of Sciences*, **106**(28), 11439–11443.
- Bollerslev, Tim. 1986. Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, **31**(3), 307 – 327.
- Cai, Jun. 1994. A Markov Model of Switching-Regime ARCH. *Journal of Business & Economic Statistics*, **12**(3), 309–316.
- Campbell, John Y., & Hentschel, Ludger. 1992. No news is good news: An asymmetric model of changing volatility in stock returns. *Journal of Financial Economics*, **31**(3), 281 – 318.

- Chang, Chiao-Yi. 2009. The Volatility's Asymmetrical Reaction to Serial Correlation: Evidences from America and Taiwan Cases. *International Research Journal of Finance and Economics*, **28**, 98–103.
- Chang, Eui Jung, Lima, Eduardo José Araújo, & Tabak, Benjamin Miranda. 2004. Testing for predictability in emerging equity markets. *Emerging Markets Review*, **5**(3), 295–316.
- Charles, Amélie, & Darné, Olivier. 2009. Variance-ratio tests of random walk: an overview. *Journal of Economic Surveys*, **23**(3), 503–527.
- Chen, Willa W., & Deo, Rohit S. 2006. The variance ratio statistic at large horizons. *Econometric Theory*, **22**(02), 206–234.
- Choi, In. 1999. Testing the Random Walk Hypothesis for Real Exchange Rates. *Journal of Applied Econometrics*, **14**(3), 293–308.
- Chordia, Tarun, Roll, Richard, & Subrahmanyam, Avanidhar. 2008. Liquidity and market efficiency. *Journal of Financial Economics*, **87**(2), 249–268.
- Cochrane, John H. 1988. How Big Is the Random Walk in GNP? *The Journal of Political Economy*, **96**(5), 893–920.
- Corradi, Valentina, Distaso, Walter, & Fernandes, Marcelo. 2012. International market links and volatility transmission. *Journal of Econometrics*, **170**(1), 117 – 141.
- Doyle, John R., & Chen, Catherine Huirong. 2009. The wandering week-day effect in major stock markets. *Journal of Banking & Finance*, **33**(8), 1388 – 1399.
- Ely, Regis Augusto. 2011. Returns Predictability and Stock Market Efficiency in Brazil. *Brazilian Review of Finance*, **9**, 571–584.
- Engle, Robert F. 1982. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, **50**(4), 987–1007.
- Escanciano, J. Carlos, & Lobato, Ignacio N. 2009. An automatic Portmanteau test for serial correlation. *Journal of Econometrics*, **151**(2), 140 – 149.

- Fama, Eugene F., & French, Kenneth R. 1988. Permanent and Temporary Components of Stock Prices. *The Journal of Political Economy*, **96**(2), 246–273.
- Ferreira, Miguel A., & Santa-Clara, Pedro. 2011. Forecasting stock market returns: The sum of the parts is more than the whole. *Journal of Financial Economics*, **100**(3), 514 – 537.
- Forbes, William P. 1996. Picking Winners? A Survey of the Mean Reversion and Overreaction of Stock Prices Literature. *Journal of Economic Surveys*, **10**, 123–158.
- French, Kenneth R. 1980. Stock returns and the weekend effect. *Journal of Financial Economics*, **8**(1), 55 – 69.
- Glosten, Lawrence R., Jagannathan, Ravi, & Runkle, David E. 1993. On the Relation between the Expected Value and the Volatility of the Nominal Excess Return on Stocks. *The Journal of Finance*, **48**(5), 1779–1801.
- Hamilton, James D, & Susmel, Raul. 1994. Autoregressive conditional heteroskedasticity and changes in regime. *Journal of Econometrics*, **64**(1), 307 – 333.
- Johnson, Simon, & Mitton, Todd. 2003. Cronyism and capital controls: evidence from Malaysia. *Journal of Financial Economics*, **67**(2), 351 – 382.
- Kim, Jae H. 2009. Automatic variance ratio test under conditional heteroskedasticity. *Finance Research Letters*, **6**(3), 179–185.
- Koutmos, Gregory. 1997. Feedback trading and the autocorrelation pattern of stock returns: further empirical evidence. *Journal of International Money and Finance*, **16**(4), 625 – 636.
- LeBaron, Blake. 1992. Some Relations Between Volatility and Serial Correlations in Stock Market Returns. *The Journal of Business*, **65**(2), 199–219.
- Lehmann, Bruce N. 1990. Fads, Martingales, and Market Efficiency. *The Quarterly Journal of Economics*, **105**(1), 1–28.

- Liu, Yanhui, Gopikrishnan, Parameswaran, Cizeau, Meyer, Peng, & Stanley, H. Eugene. 1999. Statistical properties of the volatility of price fluctuations. *Physical Review E*, **60**(Aug), 1390–1400.
- Lo, Andrew W., & MacKinlay, A. Craig. 1988. Stock Market Prices do not Follow Random Walks: Evidence from a Simple Specification Test. *The Review of Financial Studies*, **1**(1), 41–66.
- Nelson, Daniel B. 1991. Conditional Heteroskedasticity in Asset Returns: A New Approach. *Econometrica*, **59**(2), 347–370.
- Pesaran, M. Hashem, & Timmermann, Allan. 1995. Predictability of Stock Returns: Robustness and Economic Significance. *The Journal of Finance*, **50**(4), 1201–1228.
- Samuelson, Paul Anthony. 1965. Proof that properly anticipated prices fluctuate randomly. *Industrial Management Review*, **6**, 41–49.
- Scheinkman, José A., & LeBaron, Blake. 1989. Nonlinear Dynamics and Stock Returns. *The Journal of Business*, **62**(3), 311–337.
- Sentana, Enrique, & Wadhwani, Sushil. 1992. Feedback Traders and Stock Return Autocorrelations: Evidence from a Century of Daily Data. *The Economic Journal*, **102**(411), 415–425.
- Silvennoinen, Annastiina, & Teräsvirta, Timo. 2009. Modeling Multivariate Autoregressive Conditional Heteroskedasticity with the Double Smooth Transition Conditional Correlation GARCH Model. *Journal of Financial Econometrics*, **7**(4), 373–411.
- Venetis, Ioannis A., & Peel, David. 2005. Non-linearity in stock index returns: the volatility and serial correlation relationship. *Economic Modelling*, **22**(1), 1–19.
- White, Halbert. 1982. Maximum Likelihood Estimation of Misspecified Models. *Econometrica*, **50**(1), 1–25.
- Zakoian, Jean-Michel. 1994. Threshold heteroskedastic models. *Journal of Economic Dynamics and Control*, **18**(5), 931 – 955.