

Assimetria na Volatilidade de Commodities Agrícola

Paulo Sergio Ceretta

Jonas Cardona Venturini

Vanessa Rabelo Dutra Gendelsky

Resumo:

Este estudo tem por objetivo analisar o comportamento temporal das taxas de retorno e da volatilidade de cinco commodities agrícola no mercado brasileiro. Para o desenvolvimento deste estudo, foram considerados os índices mensais de preço médio recebidos pelo produtor em moeda corrente deflacionados pelo IGP-DI/FGV. O conjunto de dados abrange o período de janeiro de 1967 a fevereiro de 2006 e foram obtidos do banco de dados da FGV. As commodities analisadas foram: Algodão em caroço, Café em coco, Milho, Soja e Trigo. Com base nos resultados obtidos, pode-se afirmar que para todas as commodities analisadas, ocorre o efeito de dependência positiva relacionado ao período imediatamente anterior. Identificou-se que a série retornos do Milho é a que mais sofre influência de eventos passados. Para a volatilidade, identificou-se o efeito alavancagem apenas para o Trigo.

Área temática: *Gestão de Custos nas Empresas Agropecuárias e Agronegócios*

Assimetria na Volatilidade de *Commodities* Agrícola

Paulo Sergio Ceretta (UFSM) – ceretta@smail.ufsm.br

Jonas Cardona Venturini (UFSM) – jonasventurni@yahoo.com.br

Vanessa Rabelo Dutra Gendelsky (UFSM - FAPAS) – vanessardg@gmail.com

Resumo

Este estudo tem por objetivo analisar o comportamento temporal das taxas de retorno e da volatilidade de cinco *commodities* agrícola no mercado brasileiro. Para o desenvolvimento deste estudo, foram considerados os índices mensais de preço médio recebidos pelo produtor em moeda corrente deflacionados pelo IGP-DI/FGV. O conjunto de dados abrange o período de janeiro de 1967 a fevereiro de 2006 e foram obtidos do banco de dados da FGV. As *commodities* analisadas foram: Algodão em caroço, Café em coco, Milho, Soja e Trigo. Com base nos resultados obtidos, pode-se afirmar que para todas as *commodities* analisadas, ocorre o efeito de dependência positiva relacionado ao período imediatamente anterior. Identificou-se que a série retornos do Milho é a que mais sofre influência de eventos passados. Para a volatilidade, identificou-se o efeito alavancagem apenas para o Trigo.

Palavras-chave: Commodities, Volatilidade, Alavancagem.

Área Temática: Selecionar uma dentre as áreas temáticas do Congresso.

1. Introdução

No contexto das finanças, é imprescindível o conhecimento de uma grande variedade de fatores genéricos e específicos que possibilitem um melhor entendimento das variações de preço no mercado. O conhecimento prévio sobre eventos e o impacto que causam no comportamento do preço de um ativo torna possível que se tomem medidas preventivas de segurança com vistas a reduzir o impacto indesejado nos resultados, aumentando, assim, a possibilidade de sucesso.

Um adequado entendimento do comportamento da volatilidade ao longo do tempo é um dos mais importantes fatores que possibilita aos investidores estruturarem estratégias de negociação baseada no *hedging* para fazer frente a instabilidade do mercado. Deve-se frisar que o bom gerenciamento do risco na comercialização é dependente de uma boa previsão da oscilação de preço das *commodities* agrícola.

A forma tradicional de se aferir a volatilidade de qualquer ativo é através do seu desvio padrão, que nada mais é do que uma perspectiva histórica de sua variação ao qual se assume que o comportamento é constante ao longo do tempo. Porém, no contexto das finanças, parece que o valor histórico e constante não é o mais importante, pois se busca entender a dinâmica relacionada ao futuro, e o futuro, mesmo tendo raízes no passado, não se comporta de modo estático. Engle (1982) foi um dos estudiosos pioneiros a enfocar a utilização da volatilidade condicional antes da volatilidade não condicional.

Relativo ao comportamento condicional, os modelos GARCH tem sido as ferramentas mais amplamente utilizadas para capturar as oscilações da volatilidade ao longo do tempo. Bollerslev, Chou e Kronos (1992) apresentam uma vasta revisão teórica com evidências empíricas da aplicação de modelos auto-regressivos com volatilidade heteroscedastica na área financeira. Os modelos GARCH capturam as oscilações na volatilidade condicional observando o erro ao quadrado e a própria volatilidade condicional em períodos anteriores.

Os modelos GARCH padrão são simétricos, ou seja, independente de a previsão do erro ser negativo ou positivo seu efeito sobre a volatilidade será a mesma. O estudo de Nelson (1991) foi o pioneiro e, posteriormente, Glosten, Jagannathan e Runkle (1993) comprovaram, no mercado americano, que a influência exercida por eventos negativos sobre a volatilidade é superior àqueles causados por eventos positivos. Essa descoberta evidencia a característica assimétrica da volatilidade condicional.

Este estudo procura aprofundar e ampliar o conhecimento sobre a volatilidade das *commodities* agrícola no mercado brasileiro. Para esse fim, é utilizado o modelo EGARCH de Nelson (1991), no qual a volatilidade é modelada no sentido de identificar possíveis evidências de efeitos assimétricos advindos dos retornos negativos e positivos. Além disso, também, é possível identificar a formação de blocos na volatilidade e o grau de persistência da mesma em cada uma das *commodities*. São investigadas as taxas de retornos do Algodão, Café, Milho, Soja e Trigo no período entre 1967:01 até 2006:02.

Após esta introdução ao assunto, o restante do artigo está organizado da seguinte maneira: na próxima seção, é apresentada uma breve revisão teórica referente aos modelos auto-regressivos com heteroscedasticidade condicional, na seção seguinte são descritos alguns aspectos metodológicos e tratamento dos dados que nortearam o estudo, após são apresentados e analisados os resultados empíricos e, por fim, na última seção conclui-se o artigo.

2. Modelos Auto-regressivos com Heteroscedasticidade Condicional

Em séries de tempo econométricas, geralmente, os modelos são construídos através da parametrização da média condicional. Supondo que $E(y_t | I_{t-1}) + \varepsilon_t$ onde a média condicional $E(y_t | I_{t-1})$ tem uma forma paramétrica, e $\{\varepsilon_t\}$ é uma seqüência aleatória não correlacionada com média zero, ou seja, $E(\varepsilon_t | I_{t-1}) = E(\varepsilon_t) = 0$ com $E(\varepsilon_t \varepsilon_k) = 0$ para $t \neq k$. Quando são estimados os parâmetros, dadas às informações em I_{t-1} , assume-se que a variância não condicional do termo de erro ε_t é constante ao longo do tempo.

Engle (1982) parametrizou a variância condicional considerando uma hipótese alternativa na qual a variância do erro varia ao longo do tempo [1]. Dessa forma, tem-se início aos modelos auto-regressivos com heteroscedasticidade condicional. A idéia básica por trás dos modelos ARCH é que a Δy_t é não correlacionada serialmente, mas apresenta dependência na volatilidade. Especificamente tem-se que:

$$\begin{aligned} r_t &= \sum_{i=1}^n \lambda_i r_{t-i} + a_t \\ a_t &= \sqrt{h_t} \varepsilon_t \\ h_t &= \alpha_0 + \sum_{i=1}^q \alpha_i a_{t-i}^2 \end{aligned} \quad [1]$$

Onde $\{\varepsilon_t\}$ é uma seqüência de variáveis aleatórias independentes e identicamente distribuídas (i.i.d.) com média zero e variância 1, $\alpha_0 > 0$, $\alpha_i \geq 0$, $i > 0$. Tsay (2002) destaca que na prática supõe-se que $\varepsilon_t \sim N(0,1)$ ou $\varepsilon_t \sim t_\nu$ (t de *student* com ν graus de liberdade). A formulação [1] define a variância condicional como uma função dos valores passados do erro ao quadrado advindos da equação da média.

Contrapondo a simplicidade dos modelos ARCH(q), têm-se a exigência da estimação de muitos parâmetros para uma adequada descrição do processo da volatilidade de um ativo. Empiricamente, ficou evidenciada a elevada ordem a ser estimada do modelo (q elevado).

Bollerslev (1986) propôs uma solução ao problema através da inclusão de um termo *Moving-average* – MA(p) o qual passou a se conhecido como *Generalized Autoregressive Conditional Heteroskedasticity* – GARCH(p,q). O modelo proposto por Bollerslev (1986) apresenta uma estrutura mais compacta e flexível, permitindo captar informações mais amplas sobre a estrutura da volatilidade do que o modelo ARCH(q). A formulação básica do modelo é descrito em [2].

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i a_{t-1}^2 + \sum_{j=1}^p \beta_j h_{t-1} \quad [2]$$

A notação da formulação [2] é idêntica à descrita em [1], acrescentando-se o fato de que se tem um componente MA(p) no processo da volatilidade e que $\sum (\alpha + \beta) < 1$. A restrição $\alpha + \beta$ tem a finalidade de garantir que a variância condicional de a_t seja finita. Se $p = 0$, o modelo GARCH(p,q) se reduz a um ARCH(q) e se $p = q = 0$, então a_t segue um processo ruído branco.

Os modelos ARCH/GARCH(p,q) tratam simetricamente os retornos, pois a volatilidade é uma função quadrática dos mesmos (resíduos de um ARMA). Atento a possibilidade de que os efeitos sobre a volatilidade de choques positivos e negativos possam ser diferentes, Nelson (1991) propôs o *Exponential Generalized Autoregressive Conditional Heteroskedasticity* – EGARCH(p,q). O modelo EGARCH permite que sejam capturados os efeitos da assimetria entre os retornos positivos e negativos. Sendo $h_t = \sigma_t^2$, o modelo EGARCH(p,q) pode ser escrito como exposto em [3].

$$\ln(h_t) = \alpha_0 + \phi \left[\frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}} \right] + \theta \left[\frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}} \right] + \beta \ln(h_{t-1}) \quad [3]$$

O modelo [3] permite capturar o efeito assimétrico através do coeficiente θ . Se $\theta \neq 0$, o efeito assimétrico deve ser incorporado na estrutura da volatilidade e se $\theta < 0$ ocorre o efeito *leverage*. A característica do EGARCH é que são utilizados os logaritmos dos valores e isto implica que o efeito *leverage* seja exponencial e não quadrático.

3. Aspectos Metodológicos

Para o desenvolvimento deste estudo, foram considerados os índices mensais de preço médio recebidos pelo produtor em moeda corrente deflacionados pelo IGP-DI/FGV. O conjunto de dados abrange o período de janeiro de 1967 a fevereiro de 2006 e foram obtidos do banco de dados da FGV. As *commodities* analisadas foram: Algodão em caroço, Café em coco, Milho, Soja e Trigo. A Tabela 1 apresenta alguns indicadores descritivos dessas mercadorias.

A taxa de retorno mensal, para cada *commodity*, foi calculada pela diferença do logaritmo do preço conforme a equação $r_{i,t} = (\ln P_{i,t} - \ln P_{i,t-1})$ onde $r_{i,t}$ é a taxa de rentabilidade do índice i no mês t , $P_{i,t}$ e $P_{i,t-1}$ são, respectivamente, o preço do índice da mercadoria i no mês t e $t-1$. Optou-se por trabalhar com índices de preço em moeda corrente deflacionados pelo IGP-DI para que os resultados não apresentassem viés da taxa de câmbio, no caso de índices em dólar americano.

Tabela 1 – Estatística descritiva das *commodities* *

<i>Commodities</i>	Algodão	Café	Milho	Soja	Trigo
Período de 1967:01 a 2006:02					
Média (%)	-0,067	0,032	-0,107	-0,113	-0,153
Desvio padrão (%)	2,604	3,591	2,631	3,271	2,758
Curtose	7,409	8,014	4,481	6,725	7,070
Assimetria	0,567	0,362	0,052	0,212	0,829
Mínimo (%)	-10,360	-18,010	-9,600	-17,650	-9,370
Máximo (%)	12,810	17,080	11,990	13,780	14,220
Observações	469	469	469	469	469

Fonte: Elaborado pelos autores.

* Retornos mensais logaritimizados do preço das *commodities* tomados em R\$ deflacionados pelo IGP-DI/FGV.

Observando-se os dados apresentados na tabela 1 e sua exposição gráfica na Figura 1, pode-se constatar que, exceto para o café, ocorreu um sensível decréscimo nos índices de preço ao longo do período de 1967:01 a 2006:02. Os elevados índices de curtose identificam que as distribuições dos retornos são leptocúrticas se comparadas com a distribuição normal. Índices elevados de curtose parecem ser uma característica marcante de ativos financeiros, por exemplo, no estudo de Ceretta e Costa Jr (2001) os autores encontraram excesso de curtose para os índices do mercado de ações da Argentina, Brasil, Chile e México.

A figura 1 ilustra, de forma gráfica, as oscilações dos índices de preço e sua taxa de variação ao longo do período analisado para cada uma das mercadorias. O declínio dos preços para níveis mais baixos, principalmente a partir de 1990 não implica, necessariamente, em prejuízo ao produtor. Há duas maneiras básicas para o preço de uma mercadoria reduzir sem ocasionar prejuízo: i) redução nas mesmas proporções nos preços dos insumos e, ii) aumento da produtividade nas lavouras. Porém, em muitos casos, a redução do preço se dá pela dinâmica de ajuste às variações de preço no mercado internacional. Nesse caso, o prejuízo é inevitável, exceto para o produtor que se utiliza de instrumentos de *hedging*.

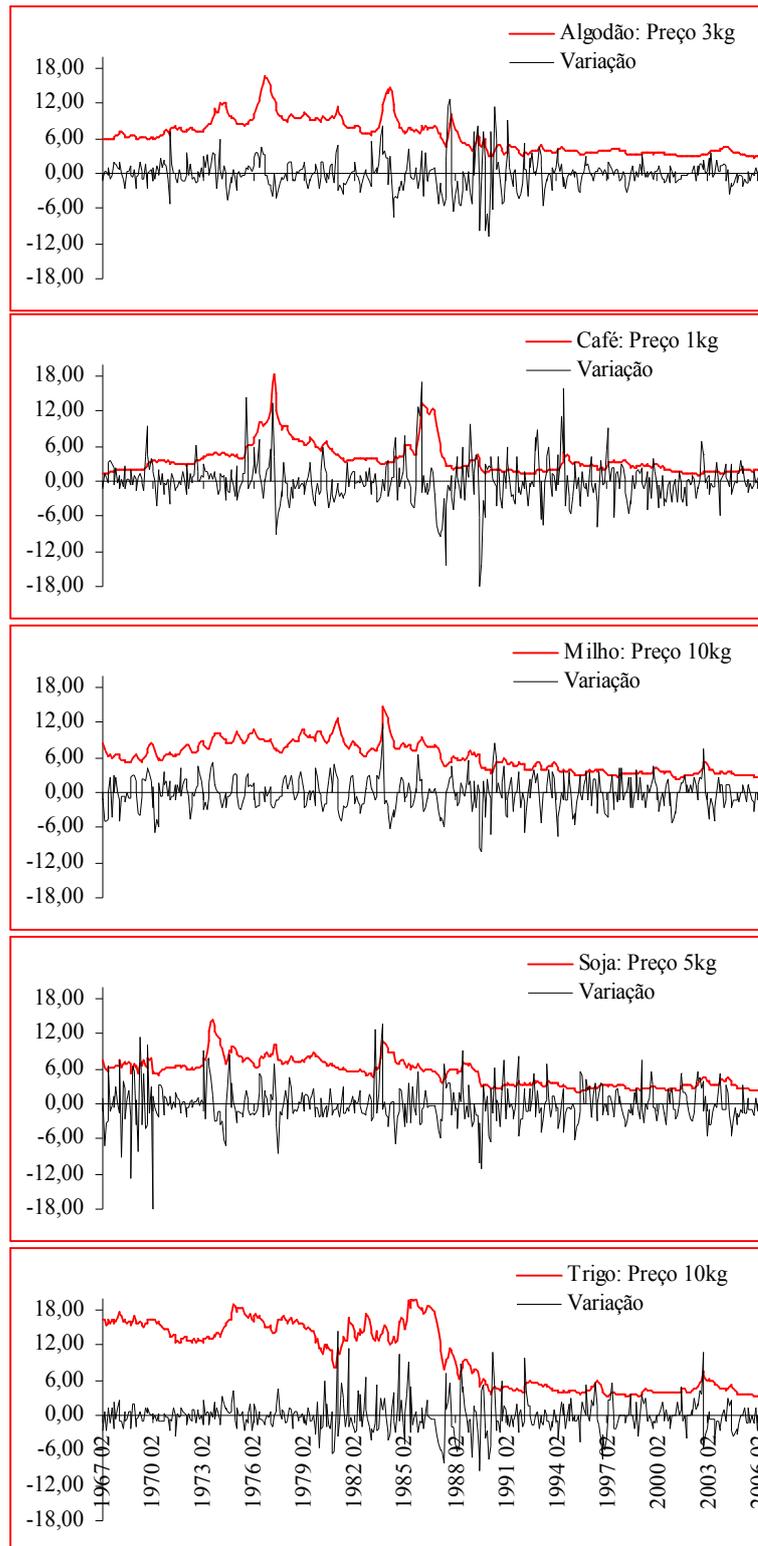


Figura 1 – Gráficos das séries de preços e retornos mensais das *commodities*
Fonte: Elaborado pelos autores.

4. Resultados Empíricos

Os resultados obtidos através do ajuste dos modelos Auto-regressivos [AR(p)] com volatilidade descritas pelo processo *Exponential Generalized Autoregressive Conditional Heteroskedastic* [EGARCH(p,q)] são apresentados na Tabela 2. Nas linhas principais, da parte superior da tabela, são evidenciados os parâmetros auto-regressivos e nas linhas secundárias seus respectivos testes de significância. De forma análoga, na parte intermediária da tabela são evidenciados os parâmetros da equação da variância e, na parte inferior, os critérios de informação utilizados para fazer a escolha das equações que apresentaram um melhor ajuste à variação dos dados.

Tabela 2 – Autocorrelação e variância condicional

<i>Commodities</i>	Algodão	Café	Milho	Soja	Trigo
Equação da média: $r_t = \sum_{i=1}^{12} \psi_i r_{t-i} + h_t$					
AR_{t-1}	0,4098 9,915	0,4152 9,2104	0,4649 12,3729	0,2289 4,3765	0,1678 3,3520
AR_{t-5}			-0,1434 -3,7070		
AR_{t-8}	-0,0767 -2,167		-0,1225 -3,4639		
AR_{t-9}		0,1035 2,0634		-0,0954 1,9073	
AR_{t-11}			0,1848 5,1905		
Equação da variância: $\ln(h_t) = \alpha_0 + \phi [\varepsilon_{t-1} /\sqrt{h_{t-1}}] + \theta [\varepsilon_{t-1}/\sqrt{h_{t-1}}] + \beta \ln(h_{t-1})$					
α_0	-0,2471 -6,0810	-0,0349 -2,2233	-0,1023 -2,2530	0,0891 2,3347	-0,1657 -4,6973
$ \varepsilon_{t-1} /\sqrt{h_{t-1}}$	0,4563 8,1978	0,1271 3,1649	0,2080 3,9949	0,2875 5,1056	0,3383 7,4150
$\varepsilon_{t-1}/\sqrt{h_{t-1}}$	0,0042 0,1259	0,0831 4,7171	0,1113 3,1821	-0,0398 -0,8463	-0,0620 -2,5130
$\ln(h_{t-1})$	0,9299 43,0799	0,9731 83,9202	0,9582 36,1680	0,8632 28,042	0,9496 72,5153
Critério de seleção dos modelos					
AIC	4,170	5,058	4,334	5,070	4,552
SIC	4,224	5,111	4,406	5,124	4,596
Ln(L)	-955,29	-1.157,25	-984,60	-1.160,23	-1.060,25

Fonte: Elaborado pelos autores.

- AIC é o critério de informação de Akaike = $-2[\ln(L)/n]+2[k/n]$;
- SIC é o critério de informação de Schwarz = $-2[\ln(L)/n]+2[\ln(k)/n]$;
- Ln(L) é a função de log-verossimilhança do modelo estimado.

Observando-se os valores apresentados na tabela 2, pode-se verificar que a equação da média identificou dependência auto-regressiva para todas as *commodities*, e em todos os casos, a dependência imediatamente anterior é positiva, ou seja, o desempenho em t-1 influencia diretamente no retorno do mês atual. Outra questão que merece destaque é relativa à série temporal do Milho. Essa *commodity* foi a que apresentou um maior número de parâmetros de dependência auto-regressiva abrangendo uma amplitude maior de tempo, ou

seja, a variação do preço do milho apresentou dependência de até 11 meses passados, tanto de forma direta como inversa. De maneira geral, para todas as *commodities* analisadas, evidenciou-se que fatos imediatamente anteriores tendem a persistir na formação do preço presente e, dentre essas *commodities*, o milho é o que apresentou uma dependência mais ampla.

Após o ajuste dos modelos auto-regressivos, para a média condicional das *commodities*, buscou-se um adequado ajuste do modelo EGARCH(p, q) com vistas a capturar possíveis evidências de persistência e assimetria no comportamento da volatilidade condicional. Na equação da variância, o coeficiente da variável $\ln(h_{t-1})^{0,5}$ fornece uma medida da persistência da volatilidade por estar se tratando de um modelo auto-regressivo do logaritmo da variância.

Para todas as *commodities* analisadas os coeficientes de persistência estimados são significativos. A persistência mais acentuada é a do Café ($\beta = 0,9731$) e a menos acentuada é a da Soja ($\beta = 0,8632$). A partir desses resultados, pode-se afirmar que choques nas séries de retornos das *commodities* Algodão, Café, Milho, Soja e Trigo terão seus efeitos diluídos ao longo do tempo na volatilidade dos mesmos. Portanto, fortes variações nos preços implicarão em diversos períodos de intensa instabilidade em busca do equilíbrio do mercado.

Depois de obtidos os coeficientes de persistência volatilidade, foi possível calcular o correspondente período de semidesintegração da volatilidade. A semidesintegração corresponde ao tempo necessário para que a volatilidade reduza sua influência pela metade, assumindo uma redução exponencial diária. Por exemplo, o Café possui um período 26,42 meses e a Soja 5,71 meses para a semidesintegração. Portanto, um choque nos preços do Café necessita 4,6 vezes mais tempo para diminuir seu efeito pela metade se comparado com o mesmo evento nos preços da Soja. O período de semidesintegração foi calculado aplicando a fórmula $\varphi = 1 - [\ln 2 / \ln \beta]$.

Relativo à possibilidade de ocorrer efeitos assimétricos na volatilidade condicional, pode-se constatar que a assimetria existe para as *commodities* Café, Milho e Trigo. Nessas *commodities* identificaram-se coeficientes estatisticamente significativos ($\theta \neq 0$) para a variável $\varepsilon_{t-1}/(h_{t-1})^{0,5}$. Este fato implica que choques positivos (*good news*) e choques negativos (*bad news*), de mesma magnitude, tem impactos distintos sobre a instabilidade do mercado. Para as *commodities* Algodão e Soja o efeito assimétrico não foi constatado, assim choques positivos e negativos, de mesma magnitude, causam idênticos impactos na instabilidade do mercado.

Dentre as *commodities* que foram constatadas efeitos assimétricos na volatilidade, apenas o Trigo apresenta o efeito alavancagem ($\theta < 0$). Para o Trigo, ocorre uma tendência de diminuição da volatilidade quando os retornos aumentam e uma tendência de elevação da volatilidade quando os retornos diminuem. Em outras palavras, pode-se dizer que choques negativos são mais danosos para a instabilidade do mercado do que seus correspondentes positivos. Porém, para o Café e o Milho esse fenômeno não ocorre.

A parte inferior da tabela 2 apresenta os valores dos três critérios de informação, a respeito do modelo a ser preferido, quanto ao número de defasagens a serem utilizadas. Na equação da média, partiu-se de uma estimativa sobre 12 defasagens a partir do qual foram eliminados os coeficientes não significativos, observando-se os critérios AIC, SIC e Ln(L). No caso específico da Soja, optou-se por manter o coeficiente da variável AR_{t-9} mesmo esta está não sendo significativa do ponto de vista estatístico, pois sua presença implicou na melhoria dos critérios de informação utilizados.

Quando da escolha dos modelos a serem ajustados aos dados, foi realizada uma bateria de testes sobre os resíduos e sobre o quadrado dos resíduos desses modelos. Tais testes devem confirmar que os modelos ajustados nas séries originais de retornos das *commodities* capturaram as informações necessárias. Se isso ocorreu, nos resíduos e nos seus quadrados

nada mais existirá de informação. A Tabela 3 apresenta os valores dos coeficientes de autocorrelação (AC), função autocorrelação parcial (PAC), estatística de Ljung-Box (*Q-Statistic*), estatística *F* e o Multiplicador de Lagrange bem como as respectivas probabilidades.

Tabela 3 – Qualidade de ajuste dos modelos

<i>Commodities</i>	Algodão	Café	Milho	Soja	Trigo
Testes nos resíduos (12 defasagens)					
AC	0,014	-0,080	0,008	0,021	0,050
PAC	0,010	-0,082	-0,001	0,014	0,046
<i>Q-Statistic</i>	9,7037	9,4891	6,0959	9,5273	7,7758
Probabilidade	0,642	0,661	0,911	0,657	0,802
Testes nos quadrados dos resíduos (12 defasagens)					
AC	0,066	-0,008	-0,050	0,047	0,006
PAC	0,055	-0,013	-0,050	0,047	0,015
<i>Q-Statistic</i>	9,8613	6,5767	8,3655	2,6097	6,8924
Probabilidade	0,628	0,884	0,756	0,998	0,865
Testes para ARCH (12 defasagens)					
<i>F-Statistic</i>	0,7284	0,4781	0,6439	0,2913	0,4965
Probabilidade	0,7238	0,9275	0,8050	0,9906	0,9168
M. Lagrange	8,8246	5,8312	7,8132	3,5197	6,0522
Probabilidade	0,7178	0,9243	0,7995	0,9899	0,9134

Fonte: Elaborado pelos autores.

- AC e PAC são os coeficientes da função de autocorrelação e função parcial de autocorrelação com limite assintótico de confiança dado por $\pm 1,96/(N)^{0,5} = 0,091$;
- *Q-Statistic* é a estatística de Ljung-Box com valor crítico tabelado de $\chi^2 = 21,026$;
- *F-Statistic* é a estatística *F* (valor crítico de $\pm 1,774$);
- M. Lagrange é o teste dos multiplicadores de Lagrange $NR^2 \sim \chi^2$.

Na parte superior da tabela 3, verifica-se que todos os coeficientes AC e PAC estão dentro dos limites assintóticos de confiança de $\pm 1,96(N)^{0,5}$, ou seja, $-0,091 \leq AC$ e $PAC \geq 0,091$. De acordo com a estatística de Ljung-Box, rejeita-se qualquer possibilidade de que os valores dos coeficientes AC e PAC estejam fora desse intervalo. Análise idêntica pode ser realizada para os valores obtidos sobre os quadrados dos resíduos, na parte intermediária da tabela. Na parte inferior da Tabela 3, ainda são apresentados testes específicos para efeitos ARCH que, de acordo com suas probabilidades, comprovam que tais efeitos foram eliminados.

Portanto, a partir dos os valores dos coeficientes de AC e PAC sobre os resíduos e seus quadrados, bem como os valores dos testes *F* e Multiplicadores de Lagrange, constata-se que, para todos os modelos ajustados AR(p)-EGARCH(p,q), as *commodities* apresentaram desempenho adequado frente às dependências lineares e quadráticas da média e da volatilidade.

5. Conclusões e Recomendações de Estudos Futuros

Este estudo teve por objetivo analisar o comportamento temporal das taxas de retorno de cinco *commodities* agrícola no mercado brasileiro. Foram analisadas as séries de retornos do Algodão, Café, Milho, Soja e Trigo. As séries de preços foram tomadas em moeda

corrente, deflacionadas e convertidas em retornos logaritmizados. O estudo utilizou-se de modelos auto-regressivos com volatilidade condicional sujeitas a choques de efeitos exponenciais.

Com base nos resultados obtidos, pode-se afirmar que para todas as *commodities* analisadas, ocorre um efeito de dependência positiva relacionado ao período imediatamente anterior, ou seja, padrões de comportamento no mês atual tendem a persistir no próximo mês. Identificou-se também que o Milho é a *commodity* que mais sofre influência de eventos passados. Nessa *commodity*, eventos ocorridos em certo mês tendem a exercer certo grau de influência na formação do preço onze meses à frente. A menor dependência foi observada para a série dos retornos do Trigo que, além de ser a menos influenciada, tal influência é originária apenas do mês imediatamente anterior.

Relativo à existência de padrões de comportamento na volatilidade, pode-se concluir que existe forte grau de persistência, principalmente para o Café. Porém, a assimetria foi identificada apenas para o Café, Milho e Trigo. O efeito alavancagem ocorre apenas para o Trigo. Especificamente para o Trigo, choques negativos nas variações de preço tendem a acarretar maiores prejuízos se comparados com as outras *commodities* e, como existe persistência, esses prejuízos se estendem por um amplo período de tempo.

A utilização de instrumentos de *hedging*, por parte do produtor, poderia ser uma alternativa para se fazer frente aos diferentes impactos de eventos positivos e negativos. Dessa forma, poderiam ser evitadas perdas de grandes volumes de recursos devido à instabilidade do mercado. Porém, se os instrumentos de *hedging* forem utilizados para as outras *commodities*, poderão ocasionar efeitos contrários. Portanto, os resultados obtidos permitem que se possa concluir que para o produtor fazer frente ao comportamento diversificado apresentado pelas *commodities*, deverá buscar cada vez mais capacitação gerencial para que possa tomar decisões específicas a fim de minimizar resultados negativos advindos da instabilidade do mercado.

Referências

BOLLERSLEV, T. (1986), Generalized autoregressive conditional heteroskedasticity. *Journal of Econometric*, v. 31, p. 307-327.

BOLLERSLEV, T.; CHOU, R. Y.; KRONER, K. F. (1992), Arch modeling in finance. *Journal of Econometrics*, v. 52, p. 5-59.

CERETTA, P. S.; COSTA, JR. N. C. A. (1999), Influência de eventos positivos e negativos sobre a volatilidade dos mercados na América Latina. *Cadernos de Pesquisa em Administração*, v. 01 n. 10, p. 35-41.

CERETTA, P. S.; COSTA, JR. N. C. A. (2001), *International portfolio diversification: The case of latin american markets*, p. 213-235. In: KOTABE, M.; LEAL, R. P. C. *Market revolution in latin America*. United Kingdom.

ENGLE, R. F. (1982), Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflations. *Econometrica*, v. 50, p. 987-1007.

GLOSTEN, L. R.; JAGANNATHAN, R.; RUNKLE, D. E. (1993) On the relation between the expected value and the volatility of the nominal excess return on stocks. *Journal of Finance*,

New york, n. 48, p. 1779-1801.

NELSON, D. B. (1991), Conditional heteroskedasticity in asset returns: a new approach. *Econometrica*, v. 59, p. 347-370.

TSAY, R. S. (2002), *Analysis of financial time series*. New York.