

Análise da variabilidade dos preços *spot* de soja de Rio Verde/GO

Cleyzer Adrian Cunha¹
Alcido Elenor Wander²

Resumo: O objetivo geral deste trabalho foi avaliar a volatilidade dos preços no mercado *spot* de soja em Rio Verde. Para tanto utilizou-se o modelo de Heterocedasticidade Condicional Auto-regressivo Generalizado (GARCH). A expansão da produção de soja em Goiás também foi acompanhada pela expansão de plantas industriais esmagadoras (produção de farelo e óleo de soja). A expansão da produção de soja em Goiás também foi acompanhada pela expansão de plantas industriais esmagadoras (produção de farelo e óleo de soja). O modelo GARCH (1,1) foi escolhido pelo menor critério de informação de Schwarz e de Akaike, quando comparado com GARCH (2,1). Portanto, os preços da soja no município de Rio Verde seguem um modelo de volatilidade condicional, GARCH (1,1). Os resultados estimados corroboram com “fatos estilizados” da região, indicando, portanto, que há baixa persistência de choques de volatilidade dos retornos do preço pago aos produtores de soja. As aquisições de soja pela Cooperativa COMIGO amortecem a variabilidade de preços, haja vista que o produto é usado como insumo para abastecer o mercado interno de óleo de soja e derivados.

Palavras-chave: variabilidade; preços spot; Rio Verde-GO

Introdução

O sistema agroindustrial da soja é um dos mais expressivos na economia brasileira, se destacando como um dos mais organizados do agronegócio. A soja desempenha papel relevante na indústria alimentícia, no tocante a produção de rações, de óleos, e de outros produtos, que são usados como insumos produtivos, por exemplo, no complexo de carnes e alimentos industrializados (gordura hidrogenada, margarina, etc.). Por conseguinte, o complexo agroindustrial da soja envolve diversos segmentos pertencentes aos elos

“a montante” (indústria de insumos) e “a jusante” (cooperativas, agroindústrias e outras), que comercializam e transacionam mercadorias e subprodutos tanto no mercado interno quanto externo. Assim sendo, a comercialização do produto se dá principalmente, pela exportação do grão (mercado externo), e também pelo processamento e transformação do grão em farelo, óleo bruto e alimentos protéicos juntos a agroindústrias espacialmente distribuídas no território brasileiro.

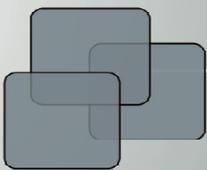
O Brasil é o segundo maior produtor mundial de soja atrás apenas dos EUA. Na safra 2009/2010, a cultura apresentou 21,7 milhões de hectares de área colhida, o que totalizou uma produção de 57,3 milhões de toneladas. A produtividade média da soja brasileira foi de 2,64 toneladas por hectares (IBGE, 2011).

Atualmente, o complexo agroindustrial da soja tem importância efetiva no desenvolvimento de Goiás, pois além de incrementar a pauta de exportação do estado com a venda da *commodity in natura* ou processada, também abastece o complexo carnes, suínos e aves. As vantagens locacionais e fiscais do governo têm atraído novos investimentos para o complexo no estado.

A expansão da produção de soja em Goiás também foi acompanhada pela expansão de plantas industriais esmagadoras (produção de farelo e óleo de soja). As agroindústrias processadoras aumentaram a capacidade e qualidade do processamento do produto *in natura*, principalmente na região de Rio Verde, em Goiás.

¹ Professor de Economia da UFG e pós-doutorando em Economia na EESP/FGV, cleyzer@face.ufg.br.

² Pesquisador da Embrapa/CNPAP e professor da ALFA e UFG, awander@cnpaf.embrapa.br



A COMIGO (Cooperativa Mista dos Produtores Rurais do Sudoeste Goiano), localizada no Sudoeste Goiano, fundada em 1975, é um exemplo de indústria em expansão dentro do complexo soja goiano. A cada ano, a empresa amplia a capacidade de esmagamento, de processamento, e de serviços complementares, tais como lojas agropecuárias de insumos e unidades armazenadoras de grãos.

Não obstante, o avanço da soja na Região de Rio Verde, o produtor ainda tem sofrido com as oscilações de preços, e perda de rentabilidade, explicados pela volatilidade no mercado mundial.

Assim, o objetivo geral deste trabalho foi avaliar a volatilidade dos preços no mercado *spot* soja em Rio Verde. Assim, utilizou-se o modelo Heterocedasticidade Condicional Auto-regressivo Generalizado (GARCH) desenvolvido por BOLLERSLEV (1986) e TAYLOR (1986).

Este estudo está dividido, em quatro partes. A primeira consiste na introdução; a segunda trata da metodologia de estudo; na terceira apresentam-se os resultados e discussões e finalmente, são apresentadas as considerações finais.

1 – Metodologia

1.1 – Modelo Auto-regressivo de Heterocedasticidade Condicional (ARCH)

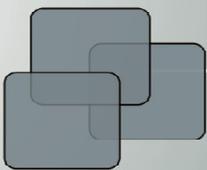
Atualmente, a previsão de volatilidade de ativos financeiros e dos preços das *commodities* agrícolas e minerais tem sido alvo de pesquisas por pesquisadores que trabalham na área de gestão de investimentos. Esses estudos têm auxiliado na seleção de carteiras de investimentos (*portfolio*) e também na precificação de derivativos. Há gama de trabalhos na literatura que usaram o modelo GARCH para analisar a volatilidade nos preços das *commodities*, tais como, ARADHYULA e HOLT (1989), HOLT (1993), JAYNE e MYERS (1994), HUDSON e COBLE (1999), e SWARAY (2002).

Para ZIEGELMANN e VALLS PEREIRA (1997), a volatilidade evidencia se o preço de um ativo está variando pouco ou muito no mercado. Ou seja, ela é uma medida da incerteza quanto às variações de preço de um período para outro. Assim, nos períodos em que a variabilidade dos preços dos ativos apresenta-se elevada, há fortes indícios de ganhos elevados e também de grandes perdas. Situação oposta, quando a volatilidade ou a variabilidade dos preços dos ativos é baixa, configura-se uma situação de menor risco. A relação é óbvia e, naturalmente, um investidor somente assumiria uma posição de alto risco caso houvesse a possibilidade de um grande retorno.

Segundo MORAIS e PORTUGAL (1999), a maneira padrão e mais simples de se medir a volatilidade de um ativo é através da estimação do desvio-padrão de seus retornos, ou seja, método de análise da volatilidade histórica. É importante salientar que, o valor histórico da variância estimado por dados passados não incorpora informação corrente sobre o mercado. Desta forma, a variância em t pode estar ou não condicionada às informações passadas. Em outras palavras, a variância não condicional pode ser constante, mas para certos períodos de grande incerteza a variância condicional pode apresentar grandes alterações por curtos períodos de tempo.

Os modelos de especificação da volatilidade condicionada utilizam a informação de preços passados para atualizar seu valor ativo no período corrente, esses modelos são conhecidos como *Autoregressive Conditional Heteroscedasticity* (ARCH). Os modelos ARCH de previsão da volatilidade foram desenvolvidos por ENGLE (1982), BOLLERSLEV (1986), TAYLOR (1986), em que, a variância condicional do termo de erro se correlaciona serialmente com os valores passados do termo de erro elevados ao quadrado.

Assim sendo, a ideia é que a variabilidade do erro de previsão das séries temporais ocorre devido especulações no mercado financeiro, as crises políticas, e falta de credibilidade na condução das políticas monetária e fiscal pelos tomadores de decisão. Frente a esses



eventos exógenos, nas séries temporais a variância dos erros de previsão não seria constante ao longo do tempo, ou seja, varia de um período para o outro, configurando o problema da autocorrelação dos resíduos.

Segundo SWARAY (2002), LUTKEPOHL e KRATZIG (2004), os modelos ARCH são definidos em termos da distribuição dos erros da dinâmica linear do modelo de regressão. Sendo assim, a variável dependente é gerada por um processo auto-regressivo, AR(1):

$$P_t = \phi_0 + \sum_{i=1}^K \phi_i P_{t-i} + \varepsilon_t \quad (1)$$

em que, P_t é o preço da soja e ε_t são os erros com média zero e variância constante. Para gerar um processo *Autoregressive Conditional Heteroskedastic* (ARCH(p)), tem-se que expressar a variância condicionada do erro do processo auto-regressivo em termos de valores de erros passados ao quadrado.

$$\varepsilon_t | \Omega_{t-1} \sim N(0, h_t), \text{ e } h_t^2 = \delta + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 \quad (2)$$

em que, h_t denota a variância condicionada ao conjunto de informações Ω_{t-1} , que são avaliadas no tempo $t - 1$, e $\delta > 0$, $\alpha_i \geq 0$ para todo $i = 2, \dots, p$ e $\alpha_1 + \alpha_2 + \alpha_3 + \dots + \alpha_m < 1$ são necessários para fazer ε_t^2 positivo e estacionário. Na equação supracitada, o parâmetro δ representa a constante.

Ainda de acordo com SWARAY (2002), pode-se representar a expressão (2) na forma de auto-regressivo média móvel (ARMA).

$$h_t^2 = \delta + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^q \beta_i h_{t-i}^2 \quad (3)$$

A equação 3 representa o modelo GARCH (1,1), em que a variância condicionada da série de preços depende da constante (δ) e das informações passadas adicionadas ao processo estocástico (ε_{t-1}^2), finalmente da variância de previsão defasada (h_{t-1}^2).

Sendo assim, pode-se representar a expressão (3), na forma reduzida pelo GARCH (1,1).

$$h_t^2 = \delta + \alpha \varepsilon_{t-1}^2 + \beta h_{t-1}^2 \quad (4)$$

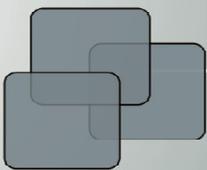
Os coeficientes da equação (4) devem situar dentro do círculo unitário, ou seja, δ é a constante, $\alpha > 0$; $\beta \geq 0$; $\alpha + \beta < 1$; e a persistência da volatilidade dos preços é mensurada pela soma dos coeficientes α e β , desta forma quanto mais próxima de um (1) for à soma, maior o tempo que um choque na série levará para dissipar-se.

Na formulação geral do modelo GARCH (p, q), a variância (h_t^2), segue as mesmas restrições para os coeficientes anteriormente, dados por:

$$h_t^2 = \delta + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j}^2 \quad (5)$$

O primeiro passo na construção de modelos família ARCH é identificar o padrão do modelo ARMA (p, q). Assim, são estabelecidas as etapas da metodologia de Box e Jenkins, que são: a) identificação do modelo pelas funções de autocorrelação (FAC) e função de autocorrelação parcial (FACP); b) estimação; e c) diagnóstico do modelo estimado. A identificação de um modelo ARMA é realizada, basicamente, com base na observação da FAC e da FACP.

Por conseguinte, depois de identificado corretamente e estimado o modelo ARMA (p,q), realiza-se o teste Q de



Ljung-Box e o teste do Multiplicador de Lagrange (ML) sobre o quadrado dos resíduos com a finalidade de verificar a presença de *Heterocedasticidade Condicional* (HC).

Segundo BUENO (2008), a hipótese nula do teste Q de *Ljung-Box* é que a soma das autocorrelações é estatisticamente diferente de zero:

$$H_0 = \sum_{j=1}^n \hat{\rho}_j = 0 \times H_A: \hat{\rho}_j \neq 0, \text{ para algum } j, \text{ onde:}$$

$$Q = T(T + 2) \sum_{j=1}^n \frac{\hat{\rho}_j^2}{T-j} \xrightarrow{d} \chi_n^2 \quad (6)$$

O teste do ML, ou teste ARCH, desenvolvido por ENGLE (1982), segundo HAMILTON (1994), é realizado sobre os resíduos ao quadrado do modelo ARMA estimado por Mínimos Quadrados Ordinários (MQO), a partir da seguinte equação defasada dos resíduos estimados:

$$\hat{u}_t^2 = \varphi + \alpha_1 \hat{u}_{t-1}^2 + \alpha_2 \hat{u}_{t-2}^2 + \alpha_3 \hat{u}_{t-3}^2 + \dots + \alpha_m \hat{u}_{t-m}^2 + e_t \quad (7)$$

Para $t = 1, 2, \dots, T$.

O teste segue distribuição *qui-quadrado*, $TR^2 \xrightarrow{d} \chi_n^2$, e é realizado pelo produto, TR^2 , onde T = tamanho da amostra e R^2 = coeficiente de determinação da equação estimada.

Segundo BUENO (2008), a regressão terá pouco poder explicativo, se os coeficientes estimados forem conjuntamente próximos de zero, de forma que o R^2 será baixo. Logo, a hipótese nula não será rejeitada, e não há presença de HC ou de um modelo ARCH. Caso contrário, rejeitando-se a hipótese nula e, verificando que há presença do ARCH, não há como definir qual modelo ideal a ser estimado pelo teste ML, pois o teste somente mostra se a covariância não condicional é ou não constante. Assim, definir o modelo ARCH correto não é tão trivial, considerando as inúmeras possibilidades oferecidas pela teoria.

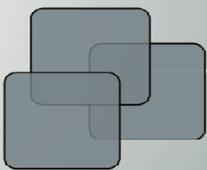
Finalmente, depois de confirmar a presença do GARCH no quadrado dos resíduos, por meio das FAC e FACp, escolhem-se as defasagens p e q do modelo. Segundo BUENO (2008), diferentemente do modelo ARMA, a FAC nos dá a ordem máxima da auto-regressão do GARCH e a FACp dá a ordem das “médias móveis”. Se $p < \max [p, q]$, sabem-se as ordens p e q do modelo. Caso contrário, encontra-se a ordem q , por tentativa e erro. As dificuldades de estimação são da mesma natureza que nos modelos ARMA (p, q) convencionais.

Destaca-se que, existe dificuldade empírica na definição do modelo GARCH ideal. Assim, nas estimativas empíricas as defasagens do GARCH são difíceis de identificar. Desta forma, a sugestão é escolher o melhor modelo ajustado dentre os vários modelos GARCH pelos menores critérios de informação de *Arkaike* e de *Schwarz*.

1.2 – Fonte de dados

O preço da soja saca de 60 kg pago ao produtor no período de 15/05/1995 a 23/08/2010 na cidade Rio Verde no Estado de Goiás foi coletado junto a Federação da Agricultura de Goiás (FAEG). Os preços são diários, e estão disponíveis para alguns dias dos meses, portanto totalizam 796 observações dentro do período supracitado. Depois da coleta dos dados, a série original passou por uma transformação matemática para se obter uma série que representa os retornos. Segundo SILVA et al. (2005) *apud* TSAY (2002) e CAMPOS (2007), existem duas razões principais para trabalhar-se com retornos em vez de preços. Primeiramente é que para investidores (produtores) médios, o retorno de um ativo é um sumário completo e independente da escala da oportunidade de investimento. Já a segunda é que séries de retornos são mais fáceis de manipular que séries de preços, dado que as primeiras têm propriedades estatísticas mais tratáveis.

Seguindo a sugestão dos autores, utilizou-se a série de retornos dada pela seguinte equação:



$R_t = \log(PS_t) - \log(PS_{t-1})$, no qual a variável $\log(PS_t)$ representa o logaritmo do preço *spot* no período t e a variável $\log(PS_{t-1})$ representa logaritmo do preço *spot* no período $t-1$.

2 – Resultados e Discussões

Pela Figura 1 pode-se analisar o comportamento da série de retornos dos preços pagos aos produtores de Rio Verde, Goiás, no período do estudo³.

Figura 1 - Retornos dos preços pagos aos produtores de soja em Rio Verde no período de estudo.

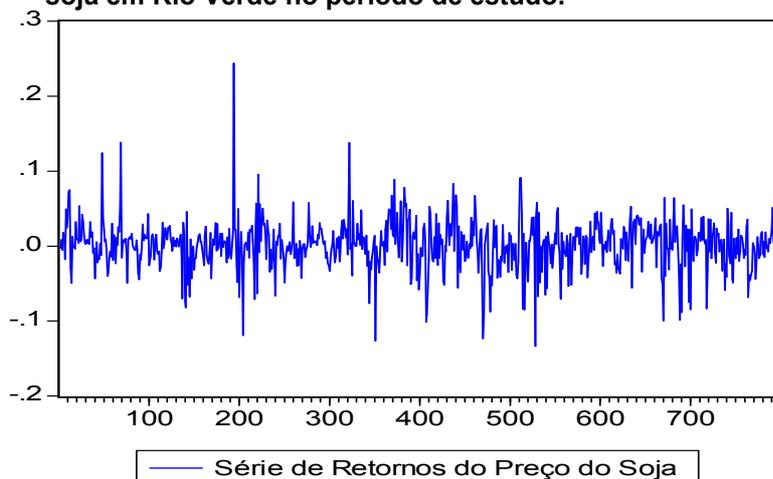


Tabela 1 mostra a FAC e a FACp para a série dos retornos do preço da soja em Rio Verde no período de estudo. Conforme a tabela, o modelo correto é o modelo AR (2) e o modelo MA (1). Nota-se que os picos das

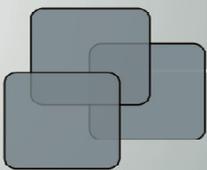
correlações não são significativos para duas defasagens no modelo AR e uma defasagem no modelo MA. Desta forma, o modelo que deve ser estimado é o modelo ARMA (2,1).

Tabela 1 - FAC e a FACp para a série dos retornos do preço da soja em Rio Verde.

K=defasagens	FAC	FACp	Q-Stat	Prob
1	0,184*	0,184*	27,080	0,000
2	0,113*	0,082	37,371	0,000
3	0,033	-0,001	38,261	0,000
4	0,024	0,009	38,706	0,000
5	-0,004	-0,013	38,722	0,000
6	0,012	0,012	38,829	0,000
7	0,047	0,047	40,610	0,000
8	0,024	0,007	41,077	0,000
9	-0,014	-0,029	41,229	0,000
10	0,012	0,015	41,345	0,000
11	0,026	0,025	41,884	0,000
12	0,034	0,025	42,812	0,000

Fonte: Resultados da pesquisa. * significativo a 1%.

³ No tratamento de séries econômicas, segundo LUTKEPOHL e KRATZIG (2004), recomenda-se o uso do teste de raiz unitária com a finalidade de verificar a ordem de integração correta da série temporal para não incorrer numa regressão espúria. O teste ADF confirmou que a série dos retornos dos preços da soja é estacionária em nível a 1% de probabilidade.



A Tabela 2 apresenta a equação ARMA (2,1) estimada por mínimos quadrados ordinários para o retorno do preço da soja em Rio Verde.

Tabela 2 – Modelo ARMA (2,1) para o retorno do preço da soja em Rio Verde.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0,001945 ^{ns}	0,001500	1,296180	0,1953
AR(2)	0,111413*	0,035864	3,106527	0,0020
MA(1)	0,169581*	0,035565	4,768136	0,0000
R-squared	0,040274	Mean dependent var		0,001951
Adjusted R-squared	0,037844	S.D. dependent var		0,032727
S.E. of regression	0,032101	Akaike info criterion		-4,036059
Sum squared resid	0,814095	Schwarz criterion		-4,018369
Log likelihood	1603,297	F-statistic		16,57569
Durbin-Watson stat	2,000583	Prob(F-statistic)		0.000000

Fonte: Resultados da pesquisa. * significativo a 1% e ns é não significativo.

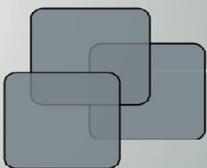
Adicionalmente, constatou-se que os resíduos do modelo ARMA (2,1) são estacionários pela aplicação do teste de ADF com intercepto e tendência. O valor calculado da estatística *tau* foi de - 26,19153, muito superior em valores absolutos aos valores críticos, tabulados por a 1%, 5% e 10% iguais a -3,969651, -3,415485 e -3,129972, respectivamente.

A Tabela 3 apresenta o teste Q de *Ljung-Box* pelo correlograma do quadrado dos resíduos. Este procedimento tem como finalidade de verificar a presença de Heterocedasticidade Condicional (HC) no quadrado dos resíduos do modelo ARMA (2,1). Nota-se pela tabela, que a defasagem 10 é significativa, indicando que há presença de HC nos resíduos do modelo estimado.

Tabela 3 - FAC e a FACp para o quadrado dos resíduos do modelo ARMA(2,1).

k=defasagens	FAC	FACp	Q-Stat	Prob
1	0,068	0,068	3,7297	0,053
2	0,027	0,022	4,3143	0,116
3	0,021	0,017	4,6552	0,199
4	0,038	0,035	5,7985	0,215
5	0,001	-0,005	5,7992	0,326
6	0,023	0,022	6,2319	0,398
7	-0,016	-0,021	6,4487	0,488
8	0,003	0,003	6,4544	0,596
9	-0,025	-0,026	6,9687	0,640
10	0,100*	0,103*	14,965	0,133
11	-0,020	-0,032	15,299	0,169
12	-0,024	-0,025	15,757	0,203

Fonte: Resultados da pesquisa. * significativo a 1%



O teste LM também confirmou presença de HC no quadrado dos resíduos. O procedimento consistiu em estimar modelo ARCH com 10 defasagens, conforme equação (7), onde a variável dependente é o quadrado dos resíduos do modelo ARMA (2,1).

O teste LM foi realizado para o modelo ARCH (10) e segue $TR^2 \xrightarrow{d} \chi_n^2$, onde o valor da estatística do teste LM de 1,666542 e *p-valor* de 0,084356,

evidenciando a rejeição da hipótese nula, indicando que o quadrado dos resíduos apresenta o comportamento ARCH.

Considerando dificuldade de definir o modelo GARCH ideal, ou mesmo as defasagens deste modelo, seguiu-se a sugestão dos autores citados na metodologia, onde dois modelos, GARCH (1,1) e GARCH (2,1) foram estimados (Tabelas 4 e 5); e a seleção do melhor modelo foi feita com base no menor critério de informação de *Arkaike* e de *Schwarz*.

Tabela 4 - Modelo GARCH (1,1) para os retornos do preço da soja em Rio Verde.

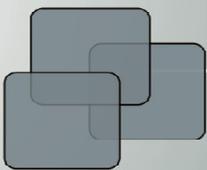
GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*GARCH(-1)				
	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	0.000596 ^{ns}	7.48E-05	7.975709	0.0000
RESID(-1)^2	0.270179*	0.051731	5.222786	0.0000
GARCH(-1)	0.210632*	0.090721	2.321747	0.0202
R-squared	-0.003574	Mean dependent var		0.001953
Adjusted R-squared	-0.006108	S.D. dependent var		0.032687
S.E. of regression	0.032786	Akaike info criterion		-4.042605
Sum squared resid	0.851352	Schwarz criterion		-4.024951
Log likelihood	1609.936	Durbin-Watson stat		1.626257

Fonte: Resultados da pesquisa. Nota: * significativo a 1% de probabilidade e ns não significativos

Tabela 5 - Modelo GARCH (2,1) para os retornos do preço da soja em Rio Verde.

GARCH = C(1) + C(2)*RESID(-1)^2 + C(3)*RESID(-2)^2 + C(4)*GARCH(-1)				
	Coefficient	Std. Error	z-Statistic	Prob.
Variance Equation				
C	0.000150 ^{ns}	9.88E-05	1.517586	0.1291
RESID(-1)^2	0.281619*	0.053595	5.254557	0.0000
RESID(-2)^2	-0.204809*	0.071880	-2.849340	0.0044
GARCH(-1)	0.793664*	0.133793	5.932028	0.0000
R-squared	-0.003574	Mean dependent var		0.001953
Adjusted R-squared	-0.007380	S.D. dependent var		0.032687
S.E. of regression	0.032807	Akaike info criterion		-4.041571
Sum squared resid	0.851352	Schwarz criterion		-4.018033
Log likelihood	1610.525	Durbin-Watson stat		1.626257

Fonte: Resultados da pesquisa. Nota: * significativo a 1% de probabilidade e ns não significativos.



De acordo com as Tabelas 4 e 5, os parâmetros estimados apresentaram-se significativos a 1% de probabilidade, conforme o *p-valor*, exceção foi o intercepto do modelo GARCH (2,1), conforme Tabela 4.

O coeficiente α_1 mede a extensão do choque no retorno atual, t , que afeta a volatilidade do retorno do tempo $t+1$,

sendo $\alpha = 0,27$ no primeiro modelo e $\alpha = 0,28$ no segundo modelo estimado.

O modelo GARCH (1,1) apresentou menores critérios de informação *Akaike* e *Schwarz*, portanto toda análise econômica foi feita com base neste modelo, conforme tabela 6.

Tabela 6 - Critérios de seleção de modelo GARCH

Critérios de seleção de modelo	Modelo GARCH (1,1)	Modelo GARCH (2,1)
Akaike	-4,04261	-4,04157
Schwarz	-4,02495	-4,01803

Fonte: Resultados da pesquisa

A soma ($\alpha_1 + \beta_1$) mostra a medida de persistência da volatilidade, ou seja, quanto do impacto de um choque no retorno em t do preço da soja em Rio Verde se propaga ao longo do tempo. Para valores do somatório dos coeficientes próximos de zero implica que um choque inicial sobre a volatilidade provocará efeitos rápidos sobre o comportamento da série. Não obstante, com o decorrer do tempo, a variância da série convergirá para a média histórica.

O estudo apresentou a soma dos coeficientes modelo GARCH (1,1) de reação (ARCH = 0,281619), juntamente com o coeficiente de persistência da volatilidade (GARCH = 0,210632) de 0,480811, indicando, portanto, alta persistência de choques de volatilidade dos retornos do preço pago aos produtores de soja. Desta forma, para uma conjuntura negativa que leva a uma redução no preço internacional da soja pode implicar baixos períodos de instabilidade ou variabilidade no mercado de soja na região de Rio Verde.

Desta forma, para uma conjuntura negativa que leva a uma redução no preço internacional da soja pode implicar em períodos de instabilidade no mercado de soja na região de Rio Verde. Com base no modelo estimado, a persistência da volatilidade é baixa, indicando que os produtores sofrem pouco com problemas de repasse de risco do preço externo no período de estudo, principalmente explicados pelas

aquisições da Cooperativa COMIGO. Assim sendo, o presente estudo mostra que um choque inicial sobre a volatilidade irá provocar efeitos mais lentos sobre o comportamento da série de retornos.

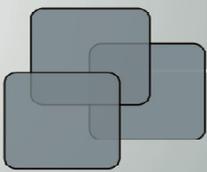
Considerações Finais

Os parâmetros do modelo GARCH (1,1) evidenciam que há baixa persistência da volatilidade do preço pago ao produtor de soja em Rio Verde, Goiás, no período de estudo.

A partir de “fatos estilizados” da economia brasileira no período de análise o mercado permaneceu estável, com predominância de efeitos exógenos positivos no mercado internacional de *commodities* ao longo dos anos, principalmente o mercado de soja, com aumento da demanda mundial, sobretudo pelas aquisições da China, o maior consumidor mundial do grão e da soja goiana.

As aquisições de soja pela Cooperativa COMIGO amortecem a variabilidade de preços, haja vista que o produto é usado como insumo para abastecer o mercado interno de óleo de soja e derivados.

De qualquer forma, sugerem-se novos estudos sobre o comportamento do preço pago ao produtor de soja de Rio Verde, principalmente, de forma a corroborar ou refutar os resultados encontrados no presente trabalho.



Referências Bibliográficas

ARADHYULA, S.V.; HOLT, M.T. Risk behavior and ration expectations in the U.S. broiler markets, **American Journal of Agricultural Economics**, 71, 892-902, 1989.

BOLLERSLEV, T. Generalized Autoregressive Conditional Heteroskedasticity. **Journal of Econometrics**, 31:307-27, 1986.

BUENO, R.L.S. **Econometria de Séries Temporais**. Cenage Learning, 2008.

CAMPOS, K.C. **Análise da volatilidade de preços de produtos agropecuários no Brasil**. Revista de Economia e Agronegócio, vol.5, Nº 3, 2007.

ENGLE R.F. Autoregressive conditional Heteroskedasticity with estimates of the Variance of United Kingdom Inflation. **Econometrica**, 50, 987-1008, 1982.

HAMILTON, J.D. **Time Series Analysis**. Princeton University Press, 1994.

HOLT, M.T. Risk response in the beef marketing channel: a multivariate generalized ARCH-M approach, **American Journal of Agricultural Economics**, 75, 559-71, 1993.

HUDSON, D.; COBLE. Harvest contract price volatility for cotton. **Journal of Future Markets**, 19, 713-733, 1999.

Instituto Brasileiro de Estatística e Geografia. Informações on-line. Disponível em www.ibge.org.br, acesso em abril de 2011.

JAYNE, T.S.; MYERS, R.J. The effect of risk on price levels and margins in international wheat markets. **Review of Agricultural economics**, 16, 63-73, 1994.

LUTKEPOHL, H., KRATZIG, M. **Applied Times Séries Econometrics**. Cambridge University Press, 2004.

MORAIS, I.A.C., PORTUGAL, M.S. **Modelagem e previsão de volatilidade determinística e estocástica para a série do Ibovespa**. Texto para discussão, UFRGS, 1999.

SILVA, W. S. da; SÁFADI, T.; CASTRO JÚNIOR, L. G. de. **Uma análise empírica da volatilidade do retorno de commodities agrícolas utilizando modelos ARCH: os casos do café e da soja**. Rio de Janeiro: Revista de Economia e Sociologia Rural, v.43, n.01, p.119 a 134. mar. 2005.

SWARAY, R.B. **Volatility of Primary Commodity Prices: Some Evidence from Agricultural Exports in Sub-Saharan Africa**, Discussion Papers in Economics, n.2002/06, University of York, 2002.

TAYLOR, S.J. **Modeling Financial Times Séries**. UK: John Wiley & Sons, 1986.

TSAY, R.S. **The analysis of financial time séries**. New York: J. WILEY, 2002.

ZIEGELMANN, F. A. e PEREIRA, P. L. V. (1997) – **Modelos de Volatilidade Estocástica com Deformação Temporal: Um Estudo Empírico para o Índice Ibovespa**. Política e Planejamento Econômico, v.27, n.2, p.353-376.