

Finanças

Perda máxima aceitável para investimento de risco em *commodity* brasileira*Maximum loss acceptable to risk investment in Brazilian commodity*Israel José dos Santos Felipe^{a,*} e Guillermo Badía Fraile^{b,*}^a Universidade Federal de Ouro Preto, Ouro Preto, MG, Brasil^b Universidad de Zaragoza, Zaragoza, Espanha

Recebido em 15 de abril de 2015; aceito em 3 de outubro de 2016

Disponível na internet em 16 de maio de 2017

Resumo

O presente trabalho teve como objetivo simular a perda máxima aceitável para o risco de investimento em uma das principais *commodities* agrícolas do Brasil, o trigo. Para o cumprimento de tal objetivo, o estudo usou a modelagem de séries temporais com processos autorregressivos de médias móveis (Arma), heterocedasticidade condicional (Garch) e valor em risco (V@R), aplicados sobre uma série histórica de preços do ativo num intervalo de dez anos. O banco de dados investigado foi coletado no site do Cepea/Esalq/USP e a motivação para escolha dessa série histórica se deu em função da importância produtiva e econômica do Estado do Paraná para todo o Brasil, porque é o maior produtor e comerciante da *commodity*. Os resultados discutidos neste *paper* revelam que a um nível de significância estatística de 1%, o produtor de trigo admite uma perda de R\$ 228,40 sobre o investimento feito e, a 5%, R\$ 174,19. Em geral, essas informações sugerem que a cada tonelada de trigo vendida, o produtor pode perder em seu investimento até R\$ 228,40. Estas e outras informações abordadas na pesquisa podem servir de ferramentas estratégicas de apoio para o processo decisório de investimento em *commodities*. A dinâmica dos preços expressa pela volatilidade do mercado pode revelar algum padrão de comportamento do ativo, o que pode ser útil para a formação de políticas *hedge*, nas quais vários produtores assumem o risco do investimento efetivado, minorando assim o impacto do mesmo sobre os produtores.

© 2017 Departamento de Administração, Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo – FEA/USP. Publicado por Elsevier Editora Ltda. Este é um artigo Open Access sob uma licença CC BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

Palavras-chave: Perda máxima; Investimento de risco; *Commodity* agrícola; Volatilidade

Abstract

This study aimed to simulate the maximum acceptable loss for the risk of investing in a major agricultural commodities in Brazil, wheat. To fulfill this objective, the study used the modeling of time series with autoregressive processes moving average (ARMA), conditional heteroskedasticity (GARCH) and value at risk (V@R), applied on a historical series of asset prices in a ten year period. The investigation database was collected in the site CEPEA/ESALQ/USP and the motivation for choosing this historical series was due to the productive and economic importance of the State of Paraná throughout Brazil, the largest producer and commodity trader. The results discussed in this paper show that a level of statistical significance of 1%, wheat producer admits a loss of R\$ 228.40 under the investment and 5% R\$ 174.19. Overall, these data suggest that every tonne of wheat sold, the producer can lose on your investment up to R\$ 228.40. These and other information covered in the survey may provide support strategic tools for decision-making investment in commodities. The dynamics of prices expressed by the market volatility may reveal some active behavior pattern, which can be useful for the formation of hedging policies, in which various producers assume the risk of the effected investment, thus minimizing the impact of the same on producers.

© 2017 Departamento de Administração, Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo – FEA/USP. Published by Elsevier Editora Ltda. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

Keywords: Maximum loss; Risk investment; Agricultural commodity; Volatility

* Autor para correspondência.

E-mails: israeljfelipe@gmail.com (I.J. Felipe), gbadiaf@unizar.es (G.B. Fraile).

A revisão por pares é da responsabilidade do Departamento de Administração, Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo – FEA/USP.

<http://dx.doi.org/10.1016/j.rege.2017.05.002>

1809-2276/© 2017 Departamento de Administração, Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo – FEA/USP. Publicado por Elsevier Editora Ltda. Este é um artigo Open Access sob uma licença CC BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

Introdução e motivação

A produção de trigo no mundo tem apresentado relevante destaque no cenário internacional. Por ser o principal componente na dieta alimentar da maioria dos países, essa *commodity* tem importante papel econômico. China, Índia e EUA são os principais produtores de trigo e apresentam produção anual superior a 60 milhões de toneladas (FAO, 2010). Hubner (2010) indica que a China é a maior produtora e que sua produção impacta diretamente na escala mundial, com cerca de 20% de toda produção. O Brasil ocupa apenas a vigésima colocação entre os maiores produtores, e isso justifica o fato do país importar quase 90% de todo trigo consumido internamente da Argentina, com preços cotados em dólares (De Lima, 2012).

No Brasil, os maiores produtores desse cereal encontram-se concentrados nas regiões Sul e Sudeste. Na atualidade, o maior produtor de trigo é o Estado do Paraná, seguido por Rio Grande do Sul e Santa Catarina. Esses três produtores representam 92% da produção brasileira de grãos no Brasil (Conab, 2010). Por outro lado, de acordo com Hubner, o Brasil participou com apenas 0,7% da produção mundial.

Faostat (2012), a produção nacional desse cereal em 2011 foi de 6 milhões de toneladas, valor não suficiente para atender à demanda interna. Complementa esta informação a Conab (2010), relevando que o consumo interno de trigo é de aproximadamente de 10 milhões de toneladas/ano. Além destas informações iniciais, destaca-se o fato de o Brasil ser um dos maiores importadores de trigo no mundo, inclusive, importa cinquenta vezes mais que os Estados Unidos (Arbitrigo, 2013).

Em relação ao Estado do Paraná, seus diversos municípios destacam-se em termos produtivos, por causa, principalmente, da inserção de novas tecnologias produtivas para esse cereal. O uso e aplicação dessas tecnologias permite o acompanhamento significativo das variações anuais de produtividade, preços e áreas plantadas (Santiago, Camargo & Margarido, 1996). Essas informações fornecem maiores aparatos produtivos para o acompanhamento agrícola das propriedades produtoras, reforçando ainda mais a necessidade do aprimoramento de estratégias financeiras eficientes para o gerenciamento de investimentos em risco (Campos, 2007).

Aliado ao aspecto produtivo relevante, o trigo apresenta uma característica digna de investigação e atenção de pesquisa: sua exposição ao risco cambial. O trigo consumido no Brasil é de origem externa, ou seja, seu preço depende da cotação de moeda estrangeira (dólar). Fortes oscilações no mercado externo repercutem no Brasil e essa relação pode ser suavizada com a criação de políticas mais eficientes de *hedge* para reduzir ou eliminar os efeitos das flutuações cambiais. A importância de estudar os aspectos produtivos e os preços de *commodities* revela a preocupação de produção de conhecimento mais especializado em temas que ajudam na gestão do risco operacional e financeiro que estão envolvidos no mercado de ativos (Lima et al., 2007).

Este *paper* foi elaborado para fornecer maiores contribuições produtivas em relação ao preço e à dinâmica de volatilidade para investimentos feitos na *commodity* trigo. O estudo revelou que em 2004, 2008 e 2013, o preço do trigo teve sua maior valorização durante os anos pesquisados (2004–2013). Por outro

lado, em 2005 e 2008 os preços do ativo tiveram uma brusca desvalorização em um curto intervalo de tempo. A série de preços apresentou média mensal de R\$ 478,32, porém destaca-se que, ao longo dos anos, o preço da *commodity* variou de R\$ 400,00 a quase R\$ 1.000,00. A partir da mensuração da $V@R$, estimou-se a perda máxima aceitável para o investimento no trigo em R\$ 228,40 a um nível de significância estatística de 1%. Para cada tonelada vendida de trigo, o produtor/comerciante pode admitir uma perda nessa ordem. Esses achados ilustram as flutuações dos preços do trigo e podem ajudar o entendimento da rentabilidade observada no investimento em ativos que dependem de previsões mais precisas sobre seus comportamentos (Lamounier, 2007).

Espera-se que, por meio das informações aqui discutidas, produtores e comerciantes de trigo, conheçam mais profundamente aspectos financeiros e estatísticos dos preços do trigo vendido no Paraná. A manipulação e a posterior implantação de modelos econométricos na modelagem e mitigação de risco podem convergir para uma formulação mais coerente de estratégias de comercialização de *commodities*. O objetivo deste estudo foi investigar qual o valor em risco ($V@R$) a um nível de confiança de 1%, para o mercado físico de trigo no Estado do Paraná, incorporando à literatura corrente os aspectos da estrutura temporal dos preços dessa *commodity*, os quais ainda são poucos explorados em estudos já publicados.

O artigo está estruturado em cinco seções. A primeira apresenta a introdução e as motivações da pesquisa. Em seguida, é feita uma revisão da literatura dos temas abordados. A terceira seção contempla os aspectos metodológicos gerais e modelagem usada. Na quarta seção, os achados do estudo são apresentados e discutidos e, por último, são apresentadas as considerações finais na quinta seção.

Literatura relacionada

Séries de tempo

Nelson (1973), Box e Jenkins (1976), Granger e Newbold (1977) e Morettin e Tolói (2006) definem uma série temporal como uma sequência de dados obtidos em intervalos de tempo regular durante um período específico, que apresentam uma dependência seriada entre as observações. A ideia de série temporal está relacionada a um conjunto de informações sobre uma variável, ordenadas em um determinado intervalo de tempo. De acordo com Pindyck e Rubinfeld (2004), pode-se usar esse comportamento passado para se ter base de uma previsão para o futuro.

Anderson e Hendry (1971) relataram que a natureza de uma série temporal e a estrutura de seu mecanismo gerador estão relacionadas com o intervalo de ocorrência das observações no tempo. Caso o levantamento das observações da série possa ser feito a qualquer momento do tempo, a série temporal é classificada como contínua, é expressa por $X(t)$ (Granger, 1977). Entretanto, de acordo com Granger e Nelson (1973), na maioria das séries, as observações são tomadas em intervalos de tempo discretos e equidistantes.

Conforme sugerem [Morettin e Tolói \(2006\)](#), uma série temporal pode ser decomposta nas componentes: tendência, sazonalidade, ciclo e componente aleatória. Os autores alegam que tendência (T_t) é um movimento regular e contínuo de longo prazo, que pode ser crescente, decrescente ou constante, funcionando como a “direção” da série. A sazonalidade (S_t) seria a oscilação que ocorre em um determinado período. Ciclos (C_t) são as oscilações periódicas de longo prazo em torno da tendência e a Componente Aleatória (a_t) representa os movimentos aleatórios existentes nas séries de tempo e que não são previstos. Assim, a série pode ser escrita através da equação $X_t = T_t + S_t + C_t + a_t$.

A presença de tais tendências caracteriza equilíbrio instável, ou seja, a série possui alguma forma de não estacionariedade. Faz-se necessário então, transformar os dados originais para encontrar o modelo mais robusto que se ajuste à série. De acordo com [Pindyck e Rubinfeld \(2004\)](#), se o processo é não estacionário, ou seja, o processo estocástico não é fixo no tempo, será difícil representar a série em intervalos de tempo passado. Para um estudo mais acurado sobre séries temporais, [De Souza \(2008\)](#) recomenda o uso de técnicas específicas e algumas considerações pontuais. Para esse autor, devem ser levadas em consideração:

- 1) A correlação das observações;
- 2) A ordem temporal das observações;
- 3) Fatores complicadores (tendências e a variação sazonal ou cíclica podem ser difíceis de estimar ou remover);
- 4) A seleção de modelos;
- 5) Saber lidar com as observações perdidas e com dados discrepantes devido à natureza sequencial.

[Da Silveira Bueno \(2011\)](#) acrescenta que, além de técnicas, é importante também para o estudo de séries de tempo, o conhecimento prévio dos conceitos:

- a) Processos estocásticos – processos aleatórios que dependem do tempo.
- b) Autocovariância e Autocorrelação – dada uma feitaira particular, s , de um processo estocástico, a função de Autocovariância é definida por:

$$\begin{aligned} \gamma_{jt} &\equiv E [(y_t - \mu_t)(y_{t-j} - \mu_{t-j})] \\ &= p \lim_{s \rightarrow \infty} \frac{1}{s} \sum_{s=1}^s (y_t^{(s)} - \mu_t)(y_{t-j}^{(s)} - \mu_{t-j}), \end{aligned}$$

se $\varepsilon_t \sim i.i.N(0, \sigma^2)$ e $y_t = \mu + \varepsilon_t$, então: $\gamma_{jt} = E(y_t - \mu_t)(y_{t-j} - \mu_{t-j}) =$

$$E(\varepsilon_t \varepsilon_{t-j}) = \begin{cases} \sigma^2, & j = 0 \\ 0, & j \neq 0 \end{cases}.$$

(Adaptado de [Da Silveira Bueno, 2011](#)).

Com a Autocovariância conhecida, a Autocorrelação pode ser estimada por $\rho_{jt} = \frac{\gamma_{jt}}{\gamma_{0t}}$. Considerando que a variância é dada

por γ_{0t} e as variâncias não condicionais de $y_t = \mu + \varepsilon_t$ e $y_t = \delta_t + \varepsilon_t$ são iguais.

- c) Estacionariedade – ideia mais importante para estimação de uma série temporal. Através dela é possível fazer inferências estatísticas sobre os parâmetros estimados.
- d) Ergodicidade – a propriedade que permite que a série de tempo mensure as médias em cada intervalo de tempo.
- e) Ruído branco – uma sequência ε_t é um ruído branco se para cada valor nela tiver média zero, variância constante e não existir relacionamento com qualquer feitaira da própria série (autocorrelação igual a zero).

Depois de conhecidos os elementos anteriormente citados, em diversas situações, o objetivo da análise de séries temporais poderá ser a feitaira de previsão de valores futuros ou relacionar estruturas de uma série em relação à outra.

Volatilidade de preços

De acordo com [De Oliveira Ribeiro et al. \(2010\)](#), nos últimos 20 anos, ocorreu um forte interesse na dinâmica de preço de *commodities* em função das alterações do padrão da demanda mundial e o crescimento dos mercados futuros de ativos, como ferramenta de gestão de investimentos na indústria. O estudo da volatilidade é uma das ferramentas estatísticas mais importantes para os agentes econômicos que atuam no mercado de compra e venda de *commodities*. Empiricamente, a volatilidade de um ativo representa as alterações ocorridas nos seus preços em razão de diversos fatores relacionados ao desempenho da empresa emitente e da conjuntura econômica. A investigação sobre a volatilidade de preços permite que as organizações produtivas consigam tomar decisões de investimento em contextos de incerteza, de maneira mais clara e eficiente ([Bignotto et al., 2004](#)).

Segundo [Swaray \(2002\)](#), a origem da volatilidade é diferente de acordo com o grupo de *commodity*. No caso das *commodities* agrícolas, a volatilidade origina-se, principalmente, de distúrbios da oferta. As flutuações de demanda, de um ano para outro, por exemplo, sofrem somente modificações moderadas, ao passo que a oferta flutua consideravelmente, de acordo com variáveis climáticas e técnicas da cultura, além das expectativas e dos movimentos especulativos. Assim, esses distúrbios, combinados com a elasticidade de oferta e demanda de curto prazo, ocasionam flutuações de preços acentuadas.

A volatilidade dos mercados financeiros tem sido um assunto de grande interesse no meio acadêmico em face da incessante busca de antecipar seu comportamento. A sua previsão mostra-se importante na elaboração de estratégias de investimento, análise de risco e apreçamento de ativos. Entretanto, ainda não há um consenso sobre o modelo mais robusto a ser aplicado para estimar a volatilidade ([Otuki et al., 2008](#)). A maioria dos modelos de volatilidade tem propósito de descrever o comportamento da volatilidade passada e, por meio disto, fazer a previsão da volatilidade futura ([Arêdes, 2009](#)). Esses modelos são muito usados nos mercados financeiros para investigar a existência de comportamento assimétrico na volatilidade.

Em toda atividade financeira, praticamente, se faz necessária a previsão de volatilidade, seja ela para a gestão de riscos, precificação de derivativos, seleção de carteiras, etc. Desse modo, evidencia-se a importância de tal previsão, já que quando se trata com investimento, espera-se que a perda assumida seja a menor possível e que se tenha um maior retorno pelo investimento feito. Por fim, entende-se que a volatilidade, portanto, está relacionada à quantidade de informação que chega ao mercado, que, por sua vez, determina a atuação dos negociadores e, por consequência, as flutuações de preço. Sem uma estimativa da volatilidade, é difícil para os negociadores a identificação das situações em que os preços realmente estejam estimados corretamente (Campos, 2007).

Método

Base de dados

A presente pesquisa tem natureza exploratória e cunho quantitativo. Ela usa como base de dados as séries de preços do trigo do Estado do Paraná. A série histórica compreende períodos de safras e entressafras de 2004 a 2013. A base de dados oferecida pelo Cepea/Esalq/USP representa os preços médios mensais do trigo, em que o preço médio é dado em tonelada para o mercado disponível e à vista (o valor a prazo é descontado pela taxa NPR). O setor tritícola foi escolhido em virtude da sua importância para o mercado agrícola brasileiro, principalmente no que diz respeito às importações (Maggian & Felipe, 2009; Brum & Muller, 2010).

Modelagem

Modelo Arma (p,q)

Os modelos Arma podem ser entendidos como extensões dos modelos AR e MA. De acordo com Nelson (1973), uma simples representação desse processo é expressa em:

$$z_t = \phi_1 z_{t-1} + \dots + \phi_p z_{t-p} + \delta + u_t - \theta_1 u_{t-1} - \dots - \theta_q u_{t-2}$$

Depois da junção dos modelos AR e MA, tem-se o novo processo, cuja nomenclatura passa a ser processo autorregressivo de médias móveis de ordem *p* e *q*, ou Arma (*p,q*). Geralmente, esse tipo de processo ou modelo, é usado para poucos parâmetros, em que até mesmo um AR ou MA puro satisfaça as exigências das séries investigadas.

Nelson (1973) afirma que o modelo Arma (1,1) pode ser expresso pela função:

$$z_t = \phi_1 z_{t-1} + \delta + u_t - \theta_1 u_{t-1}$$

ou

$$\begin{aligned} z_t &= \phi_1^2 z_{t-2} + (\delta + \phi_1 \delta) + u_t + (\phi_1 - \theta_1) u_{t-1} - \phi_1 \theta_1 u_{t-2} = \phi_1^3 z_{t-3} + \\ &(\delta + \phi_1 \delta + \phi_1^2 \delta) + u_t + (\phi_1 - \theta_1) u_{t-1} + \phi_1 (\phi_1 - \theta_1) u_{t-2} - \phi_1^2 \theta_1 u_{t-3} \\ &= \frac{\delta}{1 - \phi_1} + u_t + (\phi_1 - \theta_1) u_{t-1} + \phi_1 (\phi_1 - \theta_1) u_{t-2} + \phi_1^2 (\phi_1 - \theta_1) u_{t-3} + \dots \end{aligned}$$

Se o processo for estacionário, a soma dos coeficientes $\sum_{i=0}^{\infty} \phi_1^i (\phi_1 - \theta_1)$ deve convergir, então se exige que $|\phi_1| > 1$, como no caso do processo AR (1) (Nelson, 1973). Por fim, a função de autocorrelação do processo Arma (1,1) é dada por:

$$\rho_1 = \frac{(1 - \phi_1 \theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 + 2\phi_1 \theta_1}; \rho_j = \phi_1 \rho_{j-1} \text{ para } j > 1.$$

A função de autocorrelação do Arma (*p,q*) apresenta aspectos da função MA(*q*) para as defasagens *j* < *q*, em decorrência da memória do componente de médias móveis durar apenas *q* períodos. Já, se as defasagens forem maiores que *j* + 1, os aspectos são idênticos aos de um modelo AR(*p*)¹. Portanto, o Arma (1,1) é um processo de média móvel com ordem infinita. No entanto, Nelson (1973) recomenda que se deva aproximá-lo com um processo MA de ordem finita, acrescentando coeficientes pontuais em que o termo $\phi_1^i (\phi_1 - \theta_1)$ torna-se menor que algumas quantidades arbitradas.

Modelo Garch

O modelo Garch baseia-se na especificação do modelo Arch de ordem infinita e *g_t* pode ser matematizado como:

$$g_t = k + \sum_{i=1}^q \alpha_{t-i} u_{t-1}^2 + \sum_{j=1}^p \beta_{t-j} g_{t-j}^2$$

(adaptado de Engle, 1982)

Do mesmo modo que o modelo Arch depende de restrições para *g_t* ser positivo para todo *t*, os modelos Garch necessitam das restrições *k* > 0, $\alpha_i \geq 0$ e $\beta_j \geq 0$.

Por sua vez, Nelson e Cao (1992) notaram que as condições $\alpha_i \geq 0$ e $\beta_j \geq 0$ eram suficientemente satisfatórias, mas não necessárias, e o que acontece muitas vezes na prática é que esse modelo é estimado sem essas restrições. É importante destacar que os modelos Garch são heterocedásticos condicionais, porém apresentam variância incondicional constante. Para especificação dessa família de modelos é necessário que se admita a distribuição condicional dos termos de erro. A literatura sugere, com certa constância, para o uso das distribuições normal, *t* de Student e/ou distribuição dos erros generalizados.

Valor em risco (V@R)

O V@R mede a pior perda esperada ao longo de determinado intervalo de tempo, sob condições normais de mercado e em um certo nível de confiança. A diretriz de risco de um portfólio pode estar associada ao fato de que seu retorno num dado intervalo de tempo não será conhecido antecipadamente, todavia, existe um conjunto de retornos possíveis e mensuráveis. As probabilidades de ocorrência de cada um dos elementos desse conjunto determinarão, em última instância, o potencial de perda da carteira.

¹ Para mais informações sobre processos que incorporam tendências estocásticas ver: Bollerslev (1986), Enders (1995), Hamilton e Susmel (1994) e Campbell, Lo e MacKinlay (1997).




Figura 1. Tendência dos preços do trigo (Trigopr)
 Fonte: Dados da pesquisa.

Jorion (1999) definiu o $V@R$ em uma posição comprada em um ativo S num horizonte de tempo j , com probabilidade p , em que $0 < p < 1$: $p = P(\Delta P_j \leq V@R) = F_j(V@R)$, em que P_j representa o ganho ou a perda da posição P , dada por $\Delta P_j = P_{t+j} - P_t$; $F_j(\cdot)$. Morettin e Tolói (2006) estimam esse quantil a partir da distribuição empírica dos retornos. Se o $V@R$ calculado tem valor negativo, é porque quem tem uma posição comprada que sofre perda se $\Delta P_j < 0$. Formalmente, o $V@R$ de um portfólio de um único ativo cujos retornos (y) apresentam média 0 e Variância σ^2 [$y \sim N(0, \sigma^2)$] é dado por: $V@R = V_c \cdot \sigma \cdot P$. Nessa função, P é o valor de mercado do portfólio e V_c o valor crítico da normal, a um dado nível de significância.

Em suma, o $V@R$ é um método de mensuração de risco que usa técnicas estatísticas padrões. Pode-se dizer que ele apresenta uma predição da perda potencial de um portfólio, com determi-

nado nível de confiança, com base em um período específico de tempo devido a movimentos de preços adversos dos ativos. Segundo Jorion (2007), Hull e White (2004) e Crouhy et al. (2004), o *Value-at-Risk* é a medida mais precisa para avaliação de risco de mercado.

Resultados empíricos

A figura 1 evidencia a presença de uma forte variabilidade nos preços da *commodity* trigo. Esse elemento é percebido tanto nos ciclos quanto nas sazonalidades nos preços. Destaca-se também o comportamento cíclico dos preços, o que indica uma imperfeição na formação temporal, isto é, uma grande variabilidade nas informações do ativo. Numa última inspeção visual, percebe-se a necessidade da aplicação do teste da raiz unitária, para verificar a condição de estacionariedade da série.

A figura 2 apresenta a série sem diferenciação estatística do trigo e evidencia fortes sinais conglomerados de volatilidades nos preços. Entende-se que tal fenômeno pode ter sido gerado pela presença de autocorrelação serial originada da dependência temporal das observações, indicando que a série de preços de hoje é parcialmente afetada pelos dias anteriores. Os coeficientes de autocorrelação apresentados na sequência confirmam um padrão previsível para a média de preços do trigo do Paraná. Este aspecto de formação de preço pode estar ligado ao fato de que os agentes e, principalmente, o mercado físico não incorporam totalmente as informações de mercado no dia em que são divulgadas.




Figura 2. ACF e PACF da série inicial de preços
 Fonte: Dados da pesquisa.

Tabela 1

Teste da raiz unitária

Hipótese nula: Precotrigopr tem uma raiz unitária

		Estatística t	Prob.
Teste estatístico ADF (<i>Augmented Dickey-Fuller</i>)		-1.954233	0.6195
Valores críticos do teste:	1% level	-4.039797	
	5% level	-3.449365	
	10% level	-3.149922	

Fonte: Dados da pesquisa.

Após a feitura do teste ADF (ver [tabela 1](#)), o valor da probabilidade da existência de uma raiz unitária foi de 61,95%. Os valores críticos do teste são inferiores ao da estatística *t*, isto é, assumir-se-á que a hipótese nula seja válida ou que haja pelo menos uma raiz unitária na série de preços. Sabendo que a raiz unitária viola os princípios da estimação em séries temporais, foi implantada a primeira diferenciação na série original de preços. Pressuposto evidenciado, portanto, aplicou-se a diferença de um nível na série de preços para contornar os efeitos indesejados de autocorrelação e ciclos como ficou evidenciado na [figura 2](#).




Figura 3. Série diferenciada (Trigopr)

Fonte: Dados da pesquisa.

Na [figura 3](#), a série diferenciada, que agora é estacionária, não apresenta tendência, padrão ou nenhum comportamento cíclico. Pode-se visualizar também uma alta volatilidade na série defasada com a presença de fortes *outliers*. Logo, a expectativa presente da série de preços para a *commodity* trigo difere-se da expectativa da mesma *commodity* para o futuro.

Ao analisar as funções de autocorrelação (Acf) e autocorrelação parcial para a série diferenciada (Pacf) na [figura 4](#), verifica-se que o processo da defasagem contorna a




Figura 4. ACF e PACF da série diferenciada

Fonte: Dados da pesquisa.

Tabela 2
Característica geral da série de preços do trigo

Parâmetros	Trigopr ^a	Trigopr ^b
Média	478,32	-0,61
Assimetria	1,29	-0,19
Curtose	4,37	5,06
Desvio padrão não condicional	138,91	33,99
Jarque-Bera	41,88	21,53
p-valor J-B	0,00	0,00

Fonte: Dados da pesquisa.

^a Série inicial de preços.

^b Série defasada em uma diferença.

Tabela 3
Teste de raiz unitária

Crítérios	Trigopr ^d
Dickey e Fuller (ADF)	-5,99
Phillips-Perron (PP)	-4,63

Nota: O valor crítico a 1% de significância é -4,03.

Fonte: Dados da pesquisa.

grande parte da autocorrelação apresentada, torna-a um ruído branco e aprimora, portanto, as principais características da série. Dito isso, ainda é preciso modelá-la por algum método autorregressivo e/ou de médias móveis.

A série, neste momento, assemelha-se a um ruído branco, ou seja, a uma série aleatória. Em seguida, foram implantados os modelos Arma (p, q) e Garch, para modelar a variância. A modelagem permite que a estrutura dos componentes da série temporal seja decomposta e investigada, conforme ilustram as tabelas 2 e 3.

Como observado na tabela 2, as características gerais da série de preços informam que a média mensal dos preços do trigo é de R\$ 478,32. A assimetria é significativa e indica que a distribuição não é simétrica. Por convenção, quanto mais próxima estiver de zero, a assimetria tende a ser perfeitamente normal. O grau de curtose indica que a distribuição é leptocúrtica, ou seja, mais pontiforme do que a normal. Os coeficientes de assimetria e curtose são importantes porque ajudam na quantificação dos desvios da distribuição normal, conforme sugere Zhou (2002). O teste de normalidade proposto por Jarque e Bera (1987) demonstrou que a hipótese nula da distribuição normal da série deve ser rejeitada, considerando um p -valor de 5% de significância.

A tabela 3 apresenta os critérios que informam a presença ou ausência de raiz unitária em séries de tempo. O desejável para a modelagem de séries temporais é que a série seja estacionária, isto é, não contenha raízes unitárias. Ao tomar uma diferença na série original de preços, o problema das raízes unitárias foi resolvido, conforme indicam os resultados apresentados por Dickey e Fuller (1979) e Phillips e Perron (1988).

Os testes de Dickey-Fuller Aumentado (ADF) e Phillips-Perron (PP) reforçam o ajuste da série após a primeira diferença, ou seja, 1 lag. A partir dessa diferenciação a série pode ser modelada por processos mais completos, logo, dentre as simulações de modelos para séries temporais, o modelo autorregressivo e de médias móveis Arma (1,2) conseguiu captar com mais robustez

os efeitos do tempo na série sobre a sua média. Todavia, é necessário investigar a variância dos resíduos, desse modo, foi feita uma inspeção visual no Correlograma da série modelada (ACF e PACF), o que confirmou o ajuste do modelo Arma e também revelou a necessidade de checagem dos resíduos.

O modelo Arma (1,2) resolveu parcialmente a diferenciação e estacionariedade da série. Entretanto, percebe-se através da figura 5, um indicativo de instabilidade na variância. Desse modo foi feito o teste de heterocedasticidade de Lagrange. Esse teste admite que a hipótese nula afirma (H_0) não haver heterocedasticidade condicional na volatilidade do modelo usado. Conforme indica a tabela 4, a série modelada pelo Arma (1,2) apresenta p -valores que sugerem a rejeição de H_0 ao longo do tempo. Todavia, a partir do lag 25 os p -valores indicam a não rejeição de H_0 , revelando assim a necessidade de aprimoramento da série de preços modelada. Desse modo, implantou-se o processo GARCH para a média condicional dos resíduos. figura 6.

Ao admitir a hipótese de normalidade dos resíduos dos modelos ajustados para a média condicional da base na estimação dos modelos, adotou-se a matriz de variância-covariância ajustada apresentada por Bollerslev e Wooldridge (1992) no procedimento de estimação dos modelos da classe Arch. Assim, combinaram-se vários modelos para a média da série. O ajustamento mais robusto ponderado pelos critérios de informação de Akaike, Schwarz e Quadrado dos resíduos foi obtido pelo processo Arma (1,2) para um Garch (1,1), ajustados aos resíduos do modelo Arma para a média condicional dos retornos.

As medidas dos modelos foram estimadas pelo procedimento de Newey e West (1987), que os tornou substanciais à Heterocedasticidade e Autocorrelação no processo do resíduo. Os resultados da estimação para a média condicional e a volatilidade dos preços do trigo são apresentados na tabela 5.

Os critérios de informação escolhidos para as análises da estimação dos modelos da tabela 5 foram o AIC, com valor de 9,36; o Schwarz com 9,48; a estatística Durbin-Watson, 1,79 e a soma dos quadrados dos resíduos. As figuras 6 e 7 apresentam o comportamento volátil para a série defasada de preços do trigo paranaense e o comparativo da previsão com o ajuste atual. Destaca-se o pico de volatilidade entre o ano de 2008 e 2009 e o ajuste pontual da previsão via modelagem Arma (1,2) - Garch (1,1).

Para o cálculo do V@R, foi estimada a volatilidade condicional $\sigma_{it|t-1}$ por meio do processo Garch, descrito na tabela 5. Em seguida, foi desenvolvido o intervalo de confiança com referência na distribuição condicional das bases. O uso da volatilidade condicional suaviza problemas na estimação, atribuindo maior peso às observações mais novas. Foi usada a média dos últimos 10 dias da cotação da série de preços do trigo como elemento de referência para cálculo do V@R histórico. Desse modo, foi considerada a média (P) com o valor de R\$ 827,21 para parâmetro inicial do preço. Admitiu-se uma variância de 0,11 para todo o período em análise a fim de identificar o valor em risco a 1% e 5% de significância estatística.

Ao implantar a formulação do V@R pelo método da variância condicional (Arma/Garch), é possível encontrar um padrão instável para a série do valor em risco. De acordo com os valores apresentados na tabela 6, pode-se observar que a um nível de




Figura 5. ACF e PACF da série modelada pelo Arma (1,2)

Fonte: Dados da pesquisa.

Tabela 4
Teste de Heterocedasticidade

Resíduos Arma (1,2) incompleto para a série defasada		Resíduos Garch (1,1) para Arma (1,2) incompleto	
Lag	p-valor	Lag	p-valor
1	0,0000	1	0,0000
5	0,0220	5	0,0000
10	0,0220	10	0,0000
15	0,0084	15	0,0001
25	0,2020	25	0,0000

Fonte: Dados da pesquisa.

significância de 1% o produtor de trigo tem uma perda máxima admitida na ordem de R\$ 228,40 para cada tonelada de trigo vendido. Seguindo o mesmo raciocínio, a um nível de significância de 5%, o produtor admite uma perda máxima de R\$ 174,19. [figura 7.](#)

A [figura 8](#) apresenta o comportamento do V@R aos níveis de significância estatística de 1% e 5%, respectivamente. Percebe-se que em ambos os casos as séries apresentam comportamentos similares, porém de magnitude diferenciada. Essas informações visuais permitem uma maior clareza sobre a dinâmica do V@R,

da variabilidade dos preços e da visualização de um valor em risco para cada previsão de volatilidade de preços do trigo, mudando apenas o intervalo de confiança entre os dois níveis. Destaca-se que o V@R a 1% de confiança apresenta um *stress* maior nas últimas referências, já que neles observam-se maiores *outliers*.

Na [figura 9](#), pode-se visualizar o histograma do V@R a um nível de 1% de confiança, em que a média é de R\$ 268,97 para cada tonelada de trigo vendido. A um nível de 5% de confiança, esse valor decai para R\$ 157,49. Este decréscimo é conside-




Figura 6. Previsão para a série de preços defasada
Fonte: Dados da pesquisa.

rado normal, pois com o aumento do nível de confiança de 1% para 5%, eleva-se também a margem dos erros. Por fim, nota-se também que os dois níveis de confiança (V@R 1% e 5%) apresentam uma distribuição assimétrica positiva e curtoses que indicam distribuição mais puntiforme que a normal.

Considerações finais

Ainda que as previsões não tenham qualidade preditiva muito expressiva para os valores pontuais, apresentam boa aderência

Tabela 5
Estimação do modelo Arma (1,2) para Garch (1,1)

Variável	Coefficientes	Erro-Padrão	Estatística Z	Prob
AR(1)	0,714543	0,118064	6,052184	0,0000
MA(2)	-0,369922	0,171928	-2,151610	0,0314
Equação:				
c	61,71983	29,30880	2,105505	0,0353
ϵ_{t-1}^2	0,212219	0,094483	2,246105	0,0247
σ_{t-1}^2	0,727628	0,100608	7,232310	0,0000
R-squared	0,377551	Mean dependent var		3,255690
Adjusted R-squared	0,372091	S.D. dependent var		34,08025
S.E. of regression	27,00542	Akaike info criterion		9,367468
Sum squared resid	83139,37	Schwarz criterion		9,486157
Log likelihood	-538,3131	Hannan-Quinn criter		9,415649
Durbin-Watson stat	1,795987			

Fonte: Dados da pesquisa.

Tabela 6
Estimativas do Valor em risco (V@R)

V@R	
1%	5%
R\$ 228,40	R\$ 174,19

Fonte: Dados da pesquisa.




Figura 7. Comparativo entre os resíduos da previsão e os valores atuais
Fonte: Dados da pesquisa.

quando usadas para estimativas do cálculo do V@R. Isto acontece porque a série modelada exibiu boas condições da série empírica. Pode-se afirmar, contudo, que os preços do trigo, mostram um padrão assimétrico aos choques de informações, o que revela uma persistência nesses choques, é necessário algum tempo para dissipar-se por inteiro. Isso sugere que há certa imperfeição nos mercados revelados pela previsibilidade das tendências de forma forte, embora errática, para os valores pontuais dos preços.

A partir do uso das técnicas econométricas aplicadas foi possível precificar a volatilidade do ativo e, posteriormente, a determinação do valor em risco. As perdas em valores máximos admitidos pelos produtores de trigo aos níveis de confiança, de 1% a 5%, são de R\$ 228,40 e R\$ 174,19, respectivamente. Como neste estudo o foco foi a mensuração da perda máxima aceitável




Figura 8. V@R a 1% e 5%

Fonte: Dados da pesquisa.




Figura 9. Histograma do V@R a 1% e a 5%

Fonte: Dados da pesquisa.

a um nível de significância estatística de 1%, adotou-se, portanto, o valor de R\$ 228,40 como perda máxima na comercialização de cada tonelada de trigo para os produtores.

As informações aqui apresentadas e discutidas podem fornecer *insights* exploratórios aos produtores no âmbito da redução de custos produtivos ou no aumento da margem de comercialização. O uso de técnicas econométricas pode ajudar na mitigação de risco e apoio no processo decisório do investimento em *commodities* (Dos Santos Felipe et al., 2012). Como sugestão de estudos futuros, indica-se elaborar comparativos entre preços internacionais e nacionais, com o uso das bolsas de Chicago, Londres, dentre outras. A partir desse comparativo pode-se testar a eficiência dos mercados e apontar características estruturais que atuam explicitamente na formação de preços de *commodities*.

Referências

- Anderson, G., & Hendry, D. F. (1971). *An econometric model of United Kingdom building societies*. *Oxford Bulletin of Economics and Statistics*.
- Arêdes, A. F. D. (2009). Transmissão de preços e da volatilidade na comercialização da carne suína.
- Associação Brasileira da Indústria de Trigo – Arbitrigo. (2013). Disponível em: <<http://www.arbitrigo.com.br>>.
- Bigotto, E. C., Barossi-Filho, M., & Sampaio, R. (2004). Gestão do risco de mercado em organizações do agronegócio. *Resenha BM&F*, 4(161), 26–32.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307–327.
- Bollerslev, T., & Wooldridge, J. M. (1992). Quasi-maximum likelihood estimation and inference in dynamic models with time-varying covariances. *Econometric Reviews*, 11(2), 143–172.
- Box, G. E. P., & Jenkins, G. M. (1976). *Time series analysis: forecasting and control*. pp. 1976. San Francisco: Holden-Day.
- Brum, L. A., & Muller, P. K. (2010). *O comércio internacional e a cadeia produtiva do trigo no Brasil*.
- Campbell, J. Y., Lo, A. W. C., & MacKinlay, A. C. (1997). . pp. 149–180. *The econometrics of financial markets (2)* Princeton, NJ: Princeton University Press.
- Campos, K. C. (2007). Análise da volatilidade de preços de produtos agropecuários no Brasil. *Revista de Economia e Agronegócio – REA*, 5(3).
- Companhia Nacional de Abastecimento – Conab (2010). Acompanhamento da safra brasileira: grãos. Brasília. Disponível em: <http://www.conab.gov.br/>. Acesso em: 12 dez. 2014.
- Crouhy, M., Galai, D., & Mark, R. (2004). *Gerenciamento de risco: abordagem conceitual e prática: uma visão integrada dos riscos de crédito, operacional e de mercado (1ª ed.)*. Rio de Janeiro, São Paulo: Qualitymark, Serasa.
- Da Silveira Bueno, R. D. L. (2011). *Econometria de séries temporais*. Cengage Learning.
- De Oliveira Ribeiro, C., Sosnoski, A. A. K. B., & de Oliveira, S. M. (2010). Um modelo hierárquico para previsão de preços de *commodities* agrícolas. *Revista Produção Online*, 10(4), 719–733.

- De Souza, R. C. T. (2008). *Previsão de séries temporais utilizando rede neural treinada por filtro de Kalman e evolução diferencial*. Curitiba: Pontifícia Universidade Católica do Paraná. Tese de doutorado.
- De Lima, A. C. (2012). A utilização do hedge cambial na indústria brasileira do trigo. *Custos e @gronegocio online*, 7(3), set/dez.
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 74(366a), 427–431.
- Dos Santos Felipe, I. J., Mól, A. L. R., e Almeida, V. D. S., & de Brito, M. C. (2012). Application of ARIMA models in soybean series of prices in the north of Paraná. *Custos e Agronegócio*, 8, 78–91.
- Enders, W. (1995). *Applied Econometrics Time Series*. John Wiley and Sons, Inc.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the Econometric Society*, 987–1007.
- Food and Agriculture Organization of the United Nations - Faostat (2012). Prodstat - Crops. Disponível em: <http://faostat3.fao.org/home/index_e_s.html?locale=es#DOWNLOAD> Acesso em 18 dez. 2014.
- Granger, C. W. J., & Newbold, P. (1977). *Forecasting Economic Time Series*. pp. 1977. New York: Academic Press.
- Hamilton, J. D., & Susmel, R. (1994). Autoregressive conditional heteroskedasticity and changes in regime. *Journal of Econometrics*, 64(1), 307–333.
- Hubner, O. (2010). Análise da conjuntura do trigo safra 2009/2010. *Estado do Paraná, Secretaria da Agricultura e do Abastecimento, Departamento de Economia Rural*. Disponível em <http://www.agricultura.pr.gov.br/arquivos/File/deral/trigo_relato_2009>. Acesso em 09 ago 2016.
- Hull, J. C., & White, A. (2004). Valuation of a CDO and an n^{th} to default CDS without Monte Carlo simulation. *Journal of Derivatives*, 12(2), 8–23.
- Jarque, C. M., & Bera, A. K. (1987). A test for normality of observations and regression residuals. *International Statistical Review/Revue Internationale de Statistique*, 163–172.
- Jorion, P. (1999). *Value at risk: the new benchmark for controlling derivatives risk*. Chicago: Irwin. Tradução BM&F.
- Jorion, P. (2007). *Value at risk: the new benchmark for managing financial risk* (3rd ed.). New York: McGraw-Hill.
- Lamounier, W. M. (2007). Tendência, ciclos e sazonalidade nos preços spot do café brasileiro na NYBOT. *Gestão & Produção*, 13–23.
- Lima, R. C., Góis, M. R., & Ulises, C. (2007). Previsão de preços futuros de commodities agrícolas com diferenciações inteira e fracionária e erros heteroscedásticos. *Revista de Economia e Sociologia Rural*, 45(3), 621–644.
- Maggian, R.C., & Felipe, F. I. (2009). *Aspectos da competitividade da cadeia tritícola no Brasil e na Argentina*. XLVII Congresso da Sociedade Brasileira de Economia e Sociologia Rural – SOBER. Porto Alegre.
- Morettin, P. A., & Tolói, C. M. C. (2006). *Análise de séries temporais* (2nd ed.). São Paulo: Edgard Blücher.
- Nelson, C. R. (1973). *Applied time series analysis for managerial forecasting*. San Francisco: Holden-Day.
- Nelson, D. B., & Cao, C. Q. (1992). Inequality constraints in the univariate GARCH model. *Journal of Business and Economic Statistics*, 10, 229–235.
- Newey, W., & West, K. (1987). A simple, positive semi-definite, heteroscedasticity, and autocorrelation consistent covariance matrix. *Econometrica*, 55, 703–708.
- Otuki, T. F., Radavelli, C. H., Seabra, F., & da Costa, N. C. A., Jr. (2008). Assimetria na volatilidade dos retornos revisitada: Ibovespa, Merval e Imrex. *REGE Revista de Gestão*, 15(4), 71–84.
- Phillips, P. C., & Perron, P. (1988). Testing for a unit root in time series regression. *Biometrika*, 75(2), 335–346.
- Santiago, M. M., Camargo, M. D. L., & Margarido, M. A. (1996). Detecção e análise de outliers em séries temporais de índices de preços agrícolas no Estado de São Paulo. *Agricultura em São Paulo*, 89–115.
- Swaray, R. B. (2002). Volatility of primary commodity prices: some evidence from agricultural exports in Sub-Saharan Africa. (Nº. 02/06).
- Zhou, A. (2002). Modeling the volatility of the Heath–Jarrow–Morton model: a multifactor GARCH analysis. *Journal of Empirical Finance*, 9(1), 35–56.