

# POTENCIALIDADE DA UTILIZAÇÃO DE MODELOS DE SÉRIES TEMPORAIS NA PREVISÃO DO PREÇO DO TRIGO NO ESTADO DO PARANÁ<sup>1</sup>

Alan Figueiredo de Arêdes<sup>2</sup>  
Matheus Wemerson Gomes Pereira<sup>3</sup>

**RESUMO:** *Dada a importância do planejamento para a produção e comercialização, este artigo tem por objetivo avaliar a potencialidade da utilização de modelos de séries temporais na previsão de preços do trigo no Estado do Paraná. Dessa forma, estimaram-se modelos de séries temporais ARIMA, SARIMA, ARCH, GARCH e TARCH avaliando suas potencialidades de previsão. De acordo com os resultados, todos os modelos são eficazes na previsão do preço do trigo, dado que os preços previstos são próximos aos observados.*

**Palavras-chave:** *previsão, séries temporais, preços, trigo.*

## THE POTENTIAL USE OF TIME SERIES-BASED FORECASTING FOR WHEAT PRICES FOR PARANA STATE, BRAZIL

**ABSTRACT:** *Given the importance of production and commercialization planning, the present paper has for objective to analyze the potential use of time series models to forecast wheat prices for the in the state of Parana. Thus the forecast potential of the ARIMA, SARIMA, ARCH, GARCH and TARCH time series models was evaluated. In agreement with the results obtained, all these models are applicable and effective in forecasting wheat prices insofar as the foreseen prices were very close of to the real ones.*

**Key-words:** *forecast, temporary series, prices, wheat.*

**JEL Classification:** Q13, C22, C52.

---

<sup>1</sup>Cadastrado no CCTC, REA-15/2007.

<sup>2</sup>Economista, Mestre, Universidade Federal de Viçosa, Bolsista CNPQ-Brasil (e-mail: aredess@yahoo.com.br).

<sup>3</sup>Economista, Mestre, Universidade Federal de Viçosa, Bolsista CNPQ-Brasil (e-mail: matheuswgp@yahoo.com.br).

## 1 - INTRODUÇÃO

Segundo dados da Companhia Nacional de Abastecimento (CONAB, 2008), na safra, 2007/08, o Brasil produziu cerca de 3.832 toneladas de trigo, um crescimento de 71,50% em relação à safra 2006/07, o que se deve principalmente a elevação da produtividade de 65,70%, enquanto a área para cultivo cresceu apenas 3,5%.

Por ser considerada uma cultura de inverno, o trigo é produzido no Paraná, no Rio Grande do Sul e em menor quantidade em São Paulo, Santa Catarina, Minas Gerais e Mato Grosso do Sul, razão pela qual a produção nacional tem sido insuficiente para atender a demanda doméstica (BITENCOURT, 2000).

Com reconhecido destaque no mercado agrícola nacional, o Estado do Paraná é o maior produtor de trigo, responsável por 48,35% da produção nacional na safra 2007/08, e o Estado do Rio Grande do Sul, o segundo maior produtor nacional, tendo participado com 39,87% da produção nacional nessa mesma safra. Os dois estados são responsáveis por 88,22% da produção nacional do grão (CONAB, 2008), o que não deixa dúvida da importância desses Estados no abastecimento de trigo no Brasil.

No entanto, a produção no setor agropecuário, por depender de fatores considerados instáveis - que vão além de fatores ambientais, fatores de oferta e demanda interna e externa e, ainda, fatores de comercialização -, exerce grande influência na variabilidade do nível de preços, o que, por sua vez, impõe dificuldades no planejamento da produção e no abastecimento de mercados (TWEETEN, 1979).

Portanto, a previsão de preços torna-se um instrumento de grande relevância na tomada de decisão, isto é especialmente válido em se tratando do agronegócio, que é caracterizado pela exposição a distúrbios irregulares. Nesse sentido, as políticas de avaliação e minimização dos riscos na tomada de decisão dos produtores, são ferramentas imprescindíveis no planejamento de compradores e investidores (BRESSAN e LIMA, 2008).

Nesse contexto, este trabalho tem por objetivo avaliar a potencialidade da utilização de modelos de

séries temporais na previsão de preços do trigo no Estado do Paraná. Caso positivo, tais modelos poderão ser empregados no planejamento e comercialização das safras, gerando informações que darão suporte ao produtor em suas decisões.

## 2 - METODOLOGIA

### 2.1 - Modelo Analítico

De forma geral, há quatro diferentes modelos para realização de previsões utilizando séries temporais econômicas: modelo de regressão única, modelo de regressão com equações simultâneas, modelo auto-regressivo integrado de média móvel e modelo auto-regressivo vetorial (GUJARATI, 2000).

Neste artigo, os modelos de séries temporais auto-regressivos integrados de média móvel são usados para previsão, baseados na metodologia de Box e Jenkins (1976) e Box; Jenkins; Reinsel (1994), que dividi-se em quatro etapas.

Etapa 1 - Identificação: são identificados  $p$ ,  $d$  e  $q$ , em que  $p$  é o termo auto-regressivo (AR),  $q$  o termo média móvel (MA) e  $d$  o número de diferenças para tornar a série estacionária.

Etapa 2 - Estimativa: os parâmetros dos modelos são estimados. Nesse caso, pode-se utilizar o método de mínimos quadrados lineares ou não-lineares nos parâmetros.

Etapa 3 - Verificação: os modelos estimados são avaliados de acordo com o seu ajuste. Um teste simples é analisar se os resíduos são ruídos branco. Caso negativo, um novo modelo deve ser estimado.

Etapa 4 - Previsão: por fim, deve-se verificar a potencialidade de previsão do modelo.

#### 2.1.1 - Modelo ARIMA

O modelo ARIMA (*Autoregressive Integrated Moving Average*), desenvolvido por Box e Jenkins (1976) e Box; Jenkins; Reinsel (1994), é dado pela

estimação da regressão da variável dependente  $y$  em função das defasagens da própria variável  $y$ , indicado por  $p$  termos auto-regressivos (AR) e, em função dos erros aleatórios, indicado por  $q$ , termo-média móvel (MA). Como a maioria das séries temporais econômicas são naturalmente não-estacionárias, a aplicação do modelo ARIMA ( $p, d, q$ ) exige a transformação das mesmas, por  $d$  diferenças, para torná-las estacionárias, ao passo que as ordens  $p$  e  $q$  podem ser obtidas pela função de auto-correlação (FAC) e função de auto-correlação parcial (FACP), sendo auxiliadas pela ordem que minimiza o critério de Akaike (AIC) ou de Schwarz (SC). O modelo ARIMA pode ser apresentado como:

$$\Delta y_t = \phi + \sum_{i=1;p} \beta_i \Delta_{t-i} + u_t + \sum_{i=1;q} \alpha_i u_{t-i}, \quad (1)$$

em que  $\Delta_{t-i}$  é o operador de diferenças,  $u$  o termo de erro e  $\phi$ ,  $\beta$  e  $\alpha$  os parâmetros dos termos intercepto e componentes AR e MA, respectivamente.

### 2.1.2 - Modelo SARIMA

Como muitas séries temporais econômicas apresentam componentes sazonais em sua evolução, como é o caso das séries de preços de alguns produtos agropecuários, torna-se necessário incorporar a componente sazonal na estimativa ARIMA. O novo modelo estimado, denominado SARIMA, passa a ser composto também pelos componentes: sazonais auto-regressivos SAR (P) e média móvel SMA (Q), representado como SARIMA ( $p, d, q$ ) (P, D, Q), em que D é a ordem de diferenciação sazonal. Em forma de equação:

$$\Delta y_t = \phi + \sum_{i=1;p} \beta_i \Delta^d y_{t-i} + \sum_{t=1;p} \Lambda_i^P \Delta^D y_{t-i} + u_t + \sum_{i=1;q} \alpha_i u_{t-i} + \sum_{t=1,p} \lambda_i^Q u_{t-i}, \quad (2)$$

em que  $\Delta^d$  é o operador de diferenças normal,  $\Delta^D$  o operador de diferenças sazonal,  $\phi$  o termo intercepto,  $\beta$  o componente AR,  $\Lambda$  o componente SAR,  $\alpha$  o componente MA e  $\lambda$  o componente SMA, que são os parâmetros a serem estimados. A análise da verificação da componente sazonal e das ordens das defasagens podem ser realizadas a partir dos indicadores FAC e FACP e pelos critérios de AIC e SC.

### 2.1.3 - Modelo ARCH

Dadas as restrições do modelo ARIMA em manter a variância do erro constante ao longo do tempo, Engle (1982) sugeriu um modelo alternativo para previsões, denominado Autoregressive Conditional Heteroskedasticity (ARCH) que introduz a variância condicional do erro determinada pela defasagem ao quadrado dos erros. O modelo ARCH ( $q$ ), em que  $q$  é o número de defasagens ao quadrado dos erros, pode ser representado como:

$$\sigma_t^2 = \Phi + \sum_{i=1;q} \omega_i u_{t-i}^2, \quad (3)$$

em que  $\sigma$  é a variância condicionada, e  $\Phi$  e  $\omega$  são parâmetros dos termos intercepto e erro aleatório, respectivamente. O coeficiente  $\omega$  mede a persistência de choques sobre a variância, sendo que coeficientes próximos a um indicam que impactos de choques nos preços levam algum tempo para se dissiparem.

### 2.1.4 - Modelo GARCH

No entanto, dado o grande número de defasagens,  $q$ , freqüentemente encontrados no modelo ARCH, Bollerslev (1986) sugeriu um modelo geral e parcimonioso denominado Generalized Autoregressive Conditional Heteroskedasticity (GARCH). Tal modelo apresenta a vantagem operacional ao incor-

porar a própria variância condicional passada como fator determinante da variância condicional do erro. Dessa forma, o modelo GARCH ( $q, p$ ), onde  $q$  é o número de defasagens ao quadrado dos erros e  $p$  o número de defasagens ao quadrado da própria variância condicional, é dado como:

$$\sigma_t^2 = \Phi + \sum_{i=1;q} \omega_i u_{t-i}^2 + \sum_{j=1;p} \varphi_j \sigma_{t-j}^2 \quad (4)$$

em que  $\sigma$  é a variância condicionada, e  $\phi$ ,  $\omega$  e  $\varphi$  são parâmetros dos termos intercepto, erro aleatório e variância, respectivamente; sendo  $\Phi > 0$ ,  $\omega, \varphi \geq 0$ . A soma  $\omega + \varphi$  mede a persistência de choques sobre a variância. Quanto mais próximo de uma unidade à soma, maior o tempo necessário para que os choques se dissipem.

### 2.1.5 - Modelo TARCH

No entanto, dada a existência de movimentos assimétricos e de alavancagem no mercado financeiro, em períodos de elevações dos preços são seguidos por volatilidades menos intensas do que nos períodos de queda dos preços (SILVA; SAFADI; CASTRO JÚNIOR, 2005), e tendo o modelo GARCH não capturado esses efeitos, assimetria e alavancagem, Zakoian (1994) desenvolveu um modelo conhecido como Threshold Autoregressive Conditional Heteroskedasticity (TARCH) capaz de capturar esses efeitos assimétricos na série.

No modelo TARCH (1,1), a volatilidade condicional é dada por:

$$\sigma_t^2 = \Phi + \omega u_{t-1}^2 + \varphi \sigma_{t-1}^2 + \gamma d_{t-1} u_{t-1}^2, \quad (5)$$

em que  $\sigma$  é a variância condicionada, e  $\phi$ ,  $\omega$ ,  $\varphi$  e  $\gamma$  são parâmetros dos termos intercepto, erro aleatório, variância e variável *dummy*, respectivamente; em que a variável *dummy* será igual a  $d_{t-1} = 1$  quando  $u_{t-1} < 0$  e  $d_{t-1} = 0$  quando  $u_{t-1} > 0$ . Caso  $\gamma = 0$ , estatisticamente, não ocorre o efeito assimetria, não existindo diferença entre os choques positi-

vos ou negativos de preços sobre a volatilidade dos preços. Caso contrário,  $\gamma \neq 0$ , existe assimetria na variância, tendo  $\omega + \gamma$  captado a ocorrência de choques negativos de mercado,  $u_{t-1} < 0$ , baixista dos preços e  $\omega$  captado os efeitos de choques positivos,  $u_{t-1} > 0$ , altista dos preços. Caso  $\gamma > 0$ , ocorre o efeito alavancagem, em que choques negativos levam a maior volatilidade que choques positivos.

### 2.1.6 - Análise de estacionariedade

O teste mais simples para analisar a estacionariedade das séries temporais é dado pela obtenção dos coeficientes de auto-correlação e auto-correlação parcial e a partir dos quais são construídos os correlogramas, ou seja, as Funções de Auto-correlação (FAC) e Auto-correlação Parcial (FACP) - que são as representações gráficas das defasagens e os coeficientes de auto-correlação e auto-correlação parcial, respectivamente - e em seguida obter o intervalo de confiança para os coeficientes, na forma:

$$IC(95\%) = 0 \pm 1,96 \left( \frac{1}{\sqrt{n}} \right), \quad (6)$$

em que IC (95%) é o intervalo de confiança com 95% de significância estatística e  $n$  o tamanho da amostra. Coeficientes de auto-correlação e auto-correlação parcial fora desse intervalo, exceto para a defasagem 1, são estatisticamente diferentes de zero, sugerindo não estacionariedade da série (GUJARATI, 2000).

Para testar a hipótese conjunta de estacionariedade da série, pode-se utilizar as estatísticas de Box e Pierce ( $Q$ ) e Ljung-Box ( $LB$ ), definidas por:

$$Q = n \sum_{k=1}^m \rho_k^2 \sim \chi_m^2, \quad (7)$$

$$LB = n(n+2) \sum_{k=1}^m \left( \frac{\rho_k^2}{n-k} \right) \sim \chi_m^2, \quad (8)$$

em que Q é a estatística de Box e Pierce e LB a estatística de Ljung-Box,  $n$  o tamanho da amostra,  $m$  a duração da defasagem,  $\chi_m^2$  a distribuição qui-quadrado com  $m$  graus de liberdade,  $k$  a defasagem e  $\rho$  o coeficiente de auto-correlação ou auto-correlação parcial. Caso as estatísticas Q e LB sejam maiores que o valor crítico da estatística  $\chi_m^2$ , rejeita-se a hipótese nula de estacionariedade, sendo alguns coeficientes diferentes de zero. De forma geral, a estatística LB promove melhores resultados que a estatística Q para amostras pequenas (GUJARATI, 2000). Na aplicação das estatísticas Q e LB, o teste de hipótese, que é conjunto, é representado por:

$$\begin{aligned} H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0 \\ H_1 : \rho_1 = \rho_2 = \dots = \rho_k \neq 0 \end{aligned} \quad (9)$$

Outro teste amplamente utilizado em análise de estacionariedade de séries temporais é o teste de raiz unitária de Dickey-Fuller (DF), que testa a hipótese da existência de raiz unitária na série. Caso essa hipótese não for rejeitada, a série possui raiz unitária, não sendo estacionária.

No entanto, dado o problema de auto-correlação dos resíduos, o teste de raiz mais indicado é o de raiz unitária de Dickey-Fuller Aumentado (ADF), em que difere-se do teste de Dickey-Fuller (DF) por incorporar na equação de teste defasagens para eliminação do problema de auto-correlação dos resíduos. A equação de teste de raiz unitária ADF, em sua forma completa, com os componentes intercepto e tendência, é representado por:

$$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + \alpha_i \sum_{i=1}^m \Delta Y_{t-i} + \varepsilon_t, \quad (10)$$

em que  $\Delta$  é o operador de diferença da variável em estudo, no caso  $Y_t$ ;  $\beta_1$  e  $\beta_2$  os parâmetros intercepto e tendência, respectivamente;  $\delta$  o parâmetro da variável defasada;  $\alpha_i \sum_{i=1}^m \Delta Y_{t-i}$  o termo de di-

ferenças defasadas para evitar e retirar problemas de auto-correlações existentes nos resíduos, cujas defasagens podem ser indicadas pelos critérios estatísticos de Akaike info criterion (AIC) e Schwarz criterion (SC); e  $\varepsilon_t$  o erro aleatório. O teste ADF é usado para testar a significância estatística do parâmetro  $\delta$  estimado na equação (10), na seguinte forma:

$$\begin{aligned} H_0 : \delta_0 = 0 \\ H_1 : \delta_1 \neq 0 \end{aligned} \quad (11)$$

De acordo com Enders (1995), se a hipótese nula testada for rejeitada, isto é, se a estatística  $\tau$  ( $ta-u$ ) calculada for em valor absoluto maior do que a estatística tabelada ( $\tau_\tau$ ) na equação (10) - a um dado nível de significância estatística crítica (1%, 5% ou 10%), ou  $|\tau| > |\tau_\tau|$ , conclui-se que a série não possui raiz unitária, sendo estacionária portanto.

Entretanto, caso a hipótese nula não for rejeitada, ou seja, se  $|\tau| < |\tau_\tau|$ , deve-se analisar a significância estatística dos termos intercepto e tendência na equação de teste (10), uma vez que o teste de raiz unitária é sensível à presença desses termos. Assim, para a equação de teste (10), com intercepto e sem tendência, a estatística tabelada de teste passa a ser a  $\tau_\mu$  e para a equação sem intercepto e sem tendência, por  $\tau$ .

Dessa forma, caso a hipótese nula não for rejeitada, não se deve aceitar de imediato a existência de raiz unitária na série, e a equação de teste (10) deve ser estimada incluindo ou excluindo os termos intercepto e tendência de acordo com suas significâncias estatísticas seguindo uma seqüência lógica (ENDERS, 1995).

Confirmada a hipótese da existência de raiz unitária na série, esta deve ser diferenciada e testada novamente para a presença de raiz na série em diferenças, seguindo a seqüência anteriormente apresentada, sendo realizadas  $d$  diferenciações até que o teste de raiz unitária seja rejeitado, e a ordem de integração da série indicada por I(d). Caso a primeira diferença seja estacionária, então se trabalha com a série em primeira diferença, sendo seu grau de integração igual a 1, ou seja, I(1).

### 2.1.7 - Avaliação da *performance* de previsão dos modelos

Como critério para avaliar a *performance* de previsão dos modelos, utilizam-se os indicadores Erro Percentual de Previsão (EPP), Erro Percentual de Previsão Médio (EPPM) e Coeficiente de Desigualdade de Theil (CDT). Como se deseja ter valores previstos mais próximos possíveis aos observados, esses indicadores medem a *performance* dos modelos em suas previsões através da quantificação dos erros de previsão. Assim, quanto menor o valor do erro de previsão maior a eficácia do modelo.

**Erro Percentual de Previsão (EPP):** avalia o poder de previsão pontual dos modelos. Algebricamente, é apresentado como:

$$EPP_t = 100[(\hat{y}_t - y_t) / y_t], \quad (12)$$

em que  $\hat{y}_t$  e  $y_t$  são os preços previstos e observados no período  $t$ , respectivamente. Quanto menor o erro absoluto,  $\hat{y}_t - y_t$ , menor o  $EPP_t$  e melhor a *performance* do modelo. Quando  $EPP=0$ , a previsão é perfeita.

**Erro Percentual de Previsão Médio (EPPM):** avalia o poder de previsão médio dos modelos em um período da amostra. Algebricamente:

$$EPPM = 100 \sum_{t=T+1}^{T+h} [|\hat{y}_t - y_t| / y_t] / h, \quad (13)$$

em que  $\hat{y}_t$  e  $y_t$  são os preços previstos e observados no período  $t$ , respectivamente, e  $h$  o número de previsões realizadas, que é o período da amostra em que essas ocorreram. Quanto menor o erro absoluto,  $\hat{y}_t - y_t$ , melhor a *performance* do modelo. Quanto menor EPPM, melhor o desempenho do modelo nas previsões.

**Coeficiente de Desigualdade de Theil (CDT):** avalia o poder de previsão médio dos modelos em um período da amostra. Algebricamente:

$$CDT = \frac{\sqrt{\sum_{t=T+1}^{T+h} (\hat{y}_t - y_t)^2 / h}}{\sqrt{\sum_{t=T+1}^{T+h} \hat{y}_t^2 / h + \sum_{t=T+1}^{T+h} y_t^2 / h}}, \quad (14)$$

em que  $\hat{y}_t$  e  $y_t$  são os preços previstos e observados no período  $t$ , respectivamente, e  $h$  o número de previsões. Quanto menor o erro absoluto,  $\hat{y}_t - y_t$ , melhor a *performance* do modelo. É um indicador compreendido entre 0 e 1, sendo que quanto mais próximo de zero, melhor o desempenho do modelo.

### 2.1.8 - Base de dados

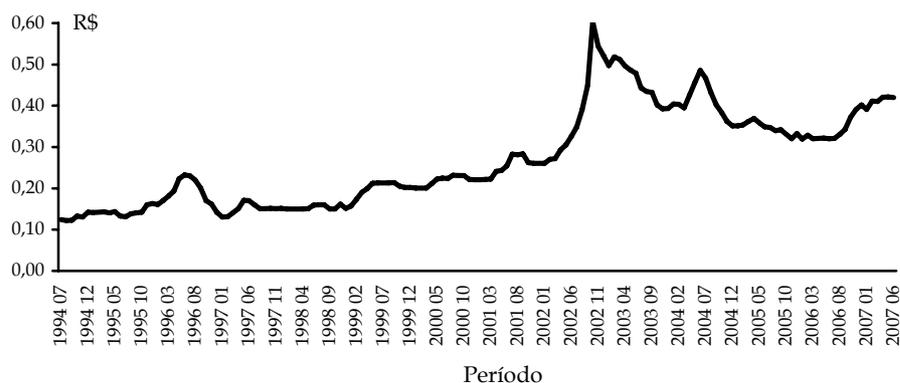
Os dados utilizados são referentes à série de preço médio real mensal do quilo do trigo recebido pelos produtores do Estado do Paraná no período de 07/1994 a 06/2007 (Figura 1), obtida junto ao IPEA (2007) e deflacionada pelo IGP-DI com período base em 06/2007.

Para verificação da potencialidade da utilização dos modelos de séries temporais na previsão de preços do trigo, utilizaram-se os preços do período de 07/1994 a 12/2005 para estimação dos modelos e os preços do período de 01/2006 a 06/2007 para confrontar os valores previstos com os observados e assim avaliando a eficácia dos modelos.

O *software* utilizado para obtenção da FAC e FACP e realização dos testes de raiz unitária, identificação, estimação, verificação e previsão dos modelos foi o *EViews* 5.0.

## 3 - RESULTADOS

A utilização dos modelos de séries temporais auto-regressivos integrados de média móvel requerem que a série temporal analisada seja estacionária. Para verificar esse requisito pode ser utilizado o teste de raiz unitária Dickey-Fuller Aumentado (ADF), empregando-se o critério de Schwarz (SC) para de-



**Figura 1** - Série de Preços Médios do Quilo do Trigo Recebido pelo Produtor no Estado do Paraná, Período de 07/1994 a 06/2007. Fonte: IPEA (2007).

terminar o número de defasagens necessárias para eliminar a possível existência de auto-correlação na série de resíduos do teste de raiz unitária.

Como na equação de teste estimada os termos intercepto e tendência foram significativos e a hipótese de existência de raiz unitária na série não foi rejeitada, pois o valor do teste calculado (-2,3266) é menor em valor absoluto que os valores críticos da estatística  $\tau_r$  a 1%, 5% e 10% de significância, a série de preços em nível (original) é não-estacionária pelo teste de raiz unitária ADF (Tabela 1).

Diante da não-estacionariedade da série de preços, trabalhou-se com a sua primeira diferença, uma vez que essa eliminou o problema da não-estacionariedade nos modelos de previsão. Como é visto na tabela 2, a primeira diferença da série de preços não apresenta raiz unitária, sendo estacionária, pois a estatística calculada, de -9,4525, foi em termos absolutos superior aos valores críticos da estatística  $\tau$  a 1%, 5% e 10% de significância. A equação de teste utilizada foi a ADF sem intercepto e sem tendência, pois esses termos não foram estatisticamente significativos a 10%.

Pela análise das Funções de Auto-correlação (FAC) e Auto-correlação Parcial (FACP) a série em nível é não-estacionária, visto que na FAC até a defasagem 36 todos os coeficientes de auto-correlação estão fora do intervalo de confiança de 95%, sendo esses coeficientes estatisticamente diferentes de zero.

Para a série ser estacionária, é necessário que os coeficientes da FAC e FACP com defasagem 1 estejam fora do intervalo de confiança e as demais defasagens dentro do intervalo. No caso da série de preços do trigo, apenas a defasagem 1 não pertence ao intervalo de confiança na FACP (Figura 2).

No entanto, as Funções de Auto-Correlação (FAC) e Auto-Correlação Parcial (FACP) da primeira diferença evidenciam que a série em primeira diferença tem apenas o coeficiente de auto-correlação com defasagem 1 fora do intervalo de confiança de 95%, sendo os demais estatisticamente iguais a zero, sugerindo-se, assim, que a série em primeira diferença seja estacionária (Figura 3).

Confirmada a hipótese da existência de raiz unitária na série, determinado a ordem de sua integração,  $I(1)$ , utilizando as informações contidas na FAC e FACP e minimizando os critérios de *Akaike* (AIC) e de *Schwarz* (SC) foram determinados os números das defasagens para estimação de quatro modelos de séries temporais com a série de preços em primeira diferença.

O primeiro modelo estimado foi o ARIMA (Tabela 3), sendo as variáveis defasadas estatisticamente significativas a 1%, tendo o modelo ARIMA (1,1,2) minimizado os valores dos critérios de AIC e SC, que foram de -4,9450 e 4,2623, respectivamente. O termo constante não foi estatisticamente significativo e o coeficiente de determinação foi muito baixo,

**Tabela 1** - Teste de Raiz Unitária ADF da Série de Preços do Trigo no Estado do Paraná em Nível (Modelo com Intercepto e Tendência e uma Defasagem<sup>1</sup>)

Variáveis	Série em nível			
	Coefficiente	Desvio padrão	Estatística t	P-valor
$P_{t-1}$	-0,0519	0,0223	-2,3266	0,0213
$\Delta P_{t-1}$	0,2809	0,0783	3,5862	0,0005
Intercepto	0,0068	0,0037	1,8045	0,0732
Tendência	0,0001	5,8E-05	1,8949	0,0600

Nível de significância	Teste de raiz unitária ADF		
	Valores críticos <sup>2</sup>	Estatística t	P-valor
1%	-4,0187	-2,3267	0,4168
5%	-3,4393		
10%	-3,1439		

<sup>1</sup>Defasagem identificada de acordo com o critério de Schwarz (SC).

<sup>2</sup>Estatística  $\tau_T$  (MACKINNON, 1996).

Fonte: Dados da pesquisa.

**Tabela 2** - Teste de Raiz Unitária ADF da Série de Preços do Trigo no Estado do Paraná em Primeira Diferença (Modelo sem Tendência e sem Defasagem<sup>1</sup>)

Variáveis	Série em primeira diferença			
	Coefficiente	Desvio padrão	Estatística t	P-valor
$P_{t-1}$	-0,7373	0,0780	-9,4525	0,0000

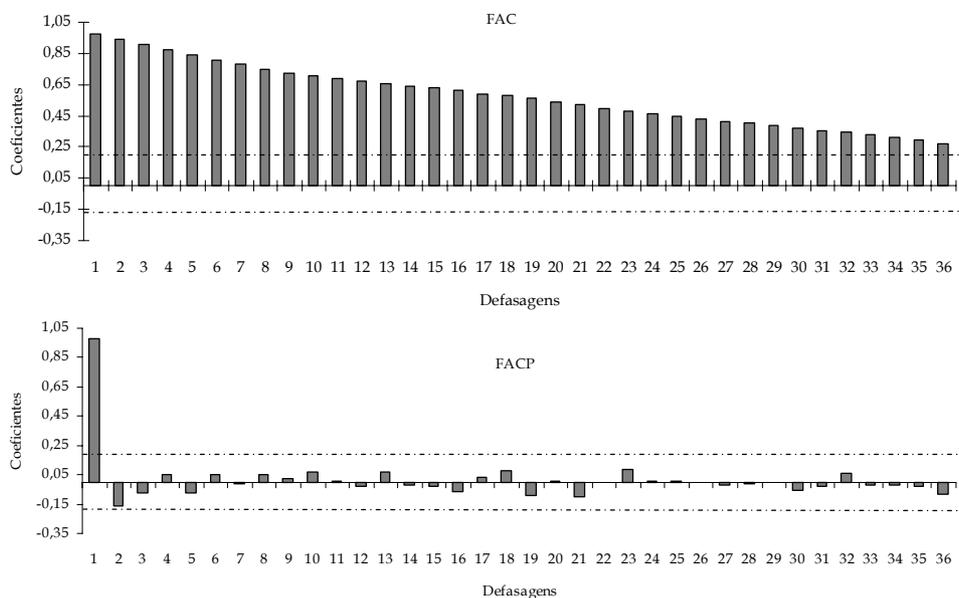
  

Nível de significância	Teste de raiz unitária ADF		
	Valores críticos <sup>2</sup>	Estatística t	P-valor
1%	-2,5800	-9,4525	0,0000
5%	-1,9429		
10%	-1,6153		

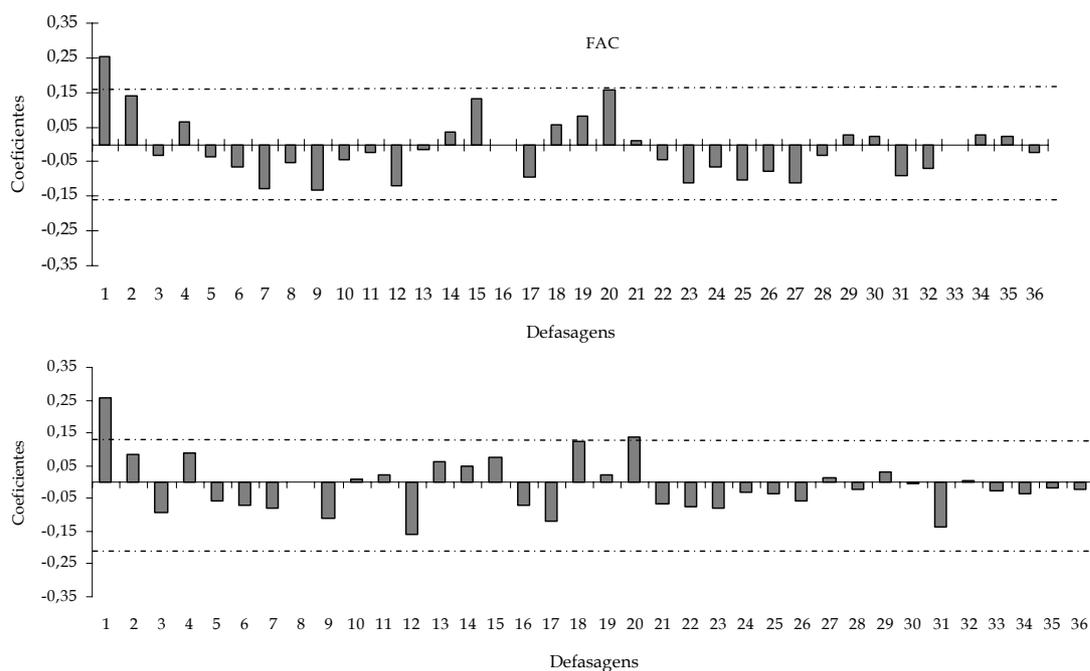
<sup>1</sup>Defasagem não identificada de acordo com o critério de Schwarz (SC).

<sup>2</sup>Estatística  $\tau$  (MACKINNON, 1996).

Fonte: Dados da pesquisa.

**Figura 2** - Funções de Auto-Correlação (FAC) e Auto-Correlação Parcial (FACP) da Série de Preços do Trigo no Estado do Paraná em Nível.

Fonte: Dados da pesquisa.



**Figura 3** - Funções de Auto-Correlação (FAC) e Auto-Correlação Parcial (FACP) da Primeira Defasagem da Série de Preços do Trigo no Estado do Paraná.

Fonte: Dados da pesquisa.

**Tabela 3** - Resultados do Modelo ARIMA (1,1,2) para a Variável Preço do Trigo no Estado do Paraná, no Período de Julho/1994 a Junho/2007

Variáveis	Coefficiente	Desvio padrão	Estatística t	P-valor
Intercepto	0,0016	0,0022	0,7436	0,4584
AR(1)	-0,7346	0,2233	-3,2896	0,0013
MA(1)	0,9895	0,2194	4,5106	0,0000
MA(2)	0,2900	0,0839	3,4542	0,0007
Akaike info criterion (AIC)	-4,9450		Estatística F	0,0066
Schwarz criterion (SC)	4,2623		R <sup>2</sup>	0,0883

Fonte: Dados da pesquisa.

o que é, entretanto, comum em modelos estimados com séries temporais univariadas em primeira diferença. Em relação aos números de defasagens encontrados para o modelo ARIMA (1,1,2), pode-se inferir que o preço está correlacionado com seu valor passado defasado em um período e com os erros aleatórios passados defasados em 1 e 2 períodos.

Embora não sejam identificadas as presenças de picos regulares com coeficientes fora do intervalo de confiança na FAC e FACP compatíveis com o comportamento sazonal, foi estimado o modelo SARIMA

minimizando os valores dos critérios de Akaike (AIC) e de Schwarz (SC) para determinação do número de defasagens, obtendo-se, assim, um modelo SARIMA (1,1,1) (1,0,0), que teve seus resultados de estimação consistentes, com apenas o coeficiente intercepto não estatisticamente significativo (Tabela 4).

Em relação ao número de defasagens encontradas no modelo SARIMA (1,1,1) (1,0,0), tem-se que o preço está correlacionado com os erros aleatórios passados defasados em um período e com o valor do preço passado defasado em 1 e 12 períodos, visto

**Tabela 4** - Resultados do Modelo SARIMA (1,1,1) (1,0,0) para a Variável Preço do Trigo no Estado do Paraná, no Período de Julho/1994 a Junho/2007

Variáveis	Coefficiente	Desvio padrão	Estatística t	P-valor
Intercepto	0,0016	0,0024	0,6571	0,5122
AR(1)	-0,8223	0,2305	-3,5672	0,0005
SAR(1)	0,3432	0,1046	3,2811	0,0013
MA(1)	0,7307	0,2937	2,4875	0,0141
<i>Akaike info criterion</i> (AIC)	-5,0221		Estatística F	0,0072
<i>Schwarz criterion</i> (SC)	-4,9361		R <sup>2</sup>	0,0877

Fonte: Dados de pesquisa.

que foi significativo um componente SAR(1), ou seja, o mês de janeiro em 2006 está correlacionado com o mês de janeiro de 2005 (Tabela 4).

Com a finalidade de testar a presença de volatilidade com padrão ARCH na série de preços, ou seja, a presença de heterocedasticidade condicional auto-regressiva, realizou-se o teste de Multiplicador de Lagrange (LM) - em que o valor da estatística calculada é dado pelo produto do coeficiente de determinação e o número de termos da amostra - nos resíduos dos modelos estimados ARIMA (1,1,2) e SARIMA (1,1,1) (1,0,0). A tabela 5 apresenta os resultados do teste LM - que segue a distribuição  $\chi^2$  (quadrado) com um grau de liberdade - indicando a presença do efeito ARCH a um nível de 5% de significância.

Dessa forma, justifica-se a utilização de modelos da família ARCH para modelagem da variância condicional, uma vez que evidenciaram-se mudanças na variância ao longo do tempo, pelo teste LM. Portanto, minimizando os valores dos critérios de Akaike (AIC) e de Schwarz (SC) estimou-se um modelo ARCH (2,1), que teve seu ajuste estatisticamente consistente e foi constatado que a variância esta condicionada ao erro aleatório passado, com um coeficiente estimado igual a 0,8390, logo, com volatilidade persistente a choques ao longo da série, uma vez que os coeficientes são próximos de um, indicando que choques de aumentos ou quedas nos preços implicam intensa volatilidade (Tabela 6).

Porém, mesmo que o modelo ARCH tenha apresentado um reduzido número de defasagens, estimou-se também um modelo GARCH para modelar a variância condicional da série de resíduos. Os

valores dos critérios de AIC e SC mínimos foram de -5,9579 e -5,7858, respectivamente, para o modelo GARCH (2,2), que apresentou um ajuste consistente, sendo todas as defasagens estatisticamente significativas a 1% (Tabela 7).

Além disso, como o somatório dos parâmetros estimados dos termos  $u_{t-i}^2$  e  $\sigma_{t-j}^2$  é de 1,0672 ocorre uma alta persistência de choques sobre a volatilidade do preço do trigo, ou seja, um choque de preço, provocado, por exemplo, por uma elevação repentina na oferta, tende a persistir ao longo da série (Tabela 7).

Por fim, estimou-se também um modelo TAR-CH para modelar a volatilidade condicional. O modelo que teve os menores valores para os critérios de AIC e SC, -6,0095 e -5,8596, respectivamente, foi o TARCH (1,1), que teve todas as defasagens estatisticamente significativas a 1% (Tabela 8).

Como a variável defasada do termo  $d_{t-1}u_{t-1}^2$  é significativa a 1%, o modelo TARCH (1,1) evidencia a existência de movimentos assimétricos na série de preço. Além disso, como o parâmetro estimado do termo  $d_{t-1}u_{t-1}^2$  é menor do que zero não ocorre o efeito alavancagem na série, em que o preço do trigo não possui maior volatilidade durante a queda do preço do que na alta (Tabela 8).

Após as estimações, foram verificados os ajustes dos modelos por meio do teste de raiz unitária ADF sem tendência e intercepto, uma vez que esses componentes não foram significativos na equação de teste de raiz unitária ADF completa, nos resíduos dos modelos estimados para checagem da hipótese de sua estacionariedade.

Os testes dos modelos ARIMA (1,1,2), SARIMA

**Tabela 5** - Resultados do Teste Multiplicador de Lagrange (LM) dos Resíduos dos Modelos Estimados ARIMA (1,1,2) e SARIMA (1,1,1) (1,0,0) para a Variável Preço do Trigo no Estado do Paraná, no Período de Julho/1994 a Junho/2007

Defasagem	ARIMA (1,1,2)		SARIMA (1,1,1) (1,0,0)	
	Estatística ML	P-valor	Estatística ML	P-valor
1	31,0094	0,0000	34,0522	0,0000
5	35,6022	0,0000	39,6218	0,0000
10	34,8286	0,0001	38,6444	0,0000
15	33,9357	0,0035	37,5914	0,0010

Fonte: Dados de pesquisa.

**Tabela 6** - Resultados do Modelo Estimado ARCH (2,1) para a Variável Preço do Trigo no Estado do Paraná, no Período de Julho/1994 a Junho/2007

Variáveis	Coefficiente	Desvio padrão	Estatística t	P-valor
Intercepto	0,0010	0,0013	0,7991	0,4243
AR(1)	-0,4464	0,1676	-2,6629	0,0077
AR(2)	0,2999	0,0821	3,6530	0,0003
MA(1)	0,7693	0,1752	4,3910	0,0000
Akaike info criterion (AIC)	-5,8443	-	Estatística F	0,0550
Schwarz criterion (SC)	-5,7152	-	R <sup>2</sup>	0,0796
Variância Condicional	-	-	-	-
$\Phi$	8,13E-05	1,17E-05	6,9348	0,0000
$u_{t-i}^2$	0,8390	0,1729	4,8527	0,0000

Fonte: Dados da pesquisa.

**Tabela 7** - Resultados do Modelo Estimado GARCH (2,2) para a Variável Preço do Trigo no Estado do Paraná, no Período de Julho/1994 a Junho/2007

Variáveis	Coefficiente	Desvio padrão	Estatística t	P-valor
Intercepto	0,0010	0,0009	1,1085	0,2677
AR(1)	-1,3316	0,1054	-12,640	0,0000
AR(2)	-0,5310	0,1086	-4,8878	0,0000
MA(1)	1,6474	0,0416	39,589	0,0000
MA(2)	0,8614	0,0467	18,449	0,0000
Akaike info criterion (AIC)	-5,9579	-	Estatística F	0,2637
Schwarz criterion (SC)	-5,7858	-	R <sup>2</sup>	0,0661
Variância Condicional	-	-	-	-
$\Phi$	1,70E-05	6,25E-06	2,7213	0,0065
$u_{t-i}^2$	0,6838	0,1699	4,0226	0,0001
$\sigma_{t-j}^2$	0,3834	0,1025	3,7420	0,0002

Fonte: Dados de pesquisa.

**Tabela 8** - Resultados do Modelo Estimado TARCH (1,1) para a Variável Preço do Trigo no Estado do Paraná, no Período de Julho/1994 a Junho/2007

Variáveis	Coefficiente	Desvio padrão	Estatística t	P-valor
Intercepto	0,0044	0,0028	1,5770	0,1148
AR(1)	0,7098	0,0874	8,1181	0,0000
MA(1)	-0,2572	0,1057	-2,4329	0,0150
Akaike info criterion (AIC)	-6,0095		Estatística F	0,9762
Schwarz criterion (SC)	-5,8596		R <sup>2</sup>	0,0092
Variância Condicional				
$\Phi$	1,65E-05	4,85E-06	3,3989	0,0007
$u_{t-i}^2$	0,8620	0,2344	3,6770	0,0002
$d_{t-1}u_{t-1}^2$	-0,9372	0,2418	-3,8766	0,0001
$\sigma_{t-j}^2$	0,6465	0,0675	9,5827	0,0000

Fonte: Dados de pesquisa.

(1,1,1) (1,0,0), GARCH (2,2) e TARCH (1,1) rejeitaram a hipótese da existência de raiz unitária nas séries dos resíduos dos modelos, sugerindo que os resíduos são estacionários, uma vez que as estatísticas calculadas foram maiores, em valor absoluto, que os valores críticos da estatística  $\tau$ , ao nível de 1%, 5% e 10% de significância (Tabela 9).

Confirmada a estacionariedade das séries dos resíduos dos modelos, utilizaram-se os modelos estimados para a realização de previsões nos preços do trigo no Estado do Paraná, no período de 01/2006 a 06/2007, para avaliação de suas potencialidades de previsão. Os preços previstos são confrontados com os observados na tabela 10, em que, observa-se que todos os modelos empregados para previsão são eficazes, uma vez que foram muito próximos os preços observados dos preços previstos no período de 01/2006 a 06/2007.

Em relação às previsões pontuais, os Erros Percentuais de Previsão (EPP) indicaram que de um total de 18 previsões realizadas por cada modelo no período de 01/2006 a 06/2007, os modelos ARCH (2,1) e TARCH (1,1) obtiveram o menor EPP em 14 previsões, o ARIMA (1,1,2) em 13, o SARIMA (1,1,1) (1,0,0) em 12 e o GARCH (2,2) em 7. Além disso, na média todos os modelos foram satisfatórios para realização de previsões, uma vez que os Erros Percentuais de Previsão Médio (EPPM) foram baixos,

sendo menores do que 3,40%, e os Coeficientes de Desigualdade de Theil (CDT) foram próximos de zero para todos os modelos, indicando alta *performance* dos modelos. Na tabela 11, as melhores previsões pontuais e médias estão em negrito.

#### 4 - CONCLUSÕES

Dada a necessidade de mecanismos eficientes para o apoio à tomada de decisão para o melhor planejamento e comercialização da produção, este artigo teve como objetivo analisar a potencialidade da utilização de modelos de séries temporais na previsão de preços do trigo no Estado do Paraná.

Como foi evidenciado pelo teste Multiplicador de Lagrange (LM), os resíduos dos modelos estimados ARIMA e SARIMA possuem heterocedasticidade condicional, sugerindo-se que os modelos ARCH, GARCH e TARCH são os mais indicados para realização das estimações e previsões de preços, uma vez que esses modelos podem modelar a variância condicional, ao contrário dos modelos ARIMA e SARIMA que possuem a variância constante ao longo do tempo.

Neste artigo, os modelos ARCH e TARCH tiveram as melhores *performances* nas previsões pontuais, embora fossem seguidos de perto pelos mo-

**Tabela 9** - Testes de Raiz Unitária sem Tendência, sem Intercepto e sem Defasagem<sup>1</sup> para as Séries de Resíduos dos Modelos Estimados

Significância	Valores críticos <sup>2</sup>	ARIMA	SARIMA	ARCH	GARCH	TARCH
1%	-2,5808	-11,4156	-11,3639	-12,2564	-6,7148	-13,4866
5%	-1,9430	-	-	-	-	-
10%	-1,6153	-	-	-	-	-

<sup>1</sup>Defasagem não identificada de acordo com o critério de Schwarz (SC).

<sup>2</sup>Estatística  $\tau$  (MACKINNON, 1996).

Fonte: Dados de pesquisa.

**Tabela 10** - Preços Observados e Previstos para a Variável Preço do Trigo no Estado do Paraná, pelos Modelos no Período de Janeiro de 2006 a Junho de 2007

(em R\$)

Mês	Observados	ARIMA	SARIMA	ARCH	GARCH	TARCH
Janeiro/2006	0,32	0,34	0,34	0,34	0,34	0,34
Fevereiro/2006	0,33	0,32	0,32	0,32	0,31	0,32
Março/2006	0,32	0,33	0,33	0,33	0,34	0,33
Abril/2006	0,32	0,32	0,32	0,32	0,31	0,32
Maiο/2006	0,32	0,32	0,32	0,32	0,32	0,32
Junho/2006	0,32	0,33	0,33	0,32	0,33	0,32
Julho/2006	0,32	0,32	0,32	0,32	0,31	0,32
Agosto/2006	0,33	0,32	0,32	0,32	0,33	0,32
Setembro/2006	0,34	0,33	0,33	0,33	0,33	0,34
Outubro/2006	0,37	0,35	0,35	0,35	0,35	0,35
Novembro/2006	0,39	0,38	0,38	0,38	0,38	0,39
Dezembro/2006	0,40	0,40	0,40	0,40	0,39	0,41
Janeiro/2007	0,39	0,40	0,41	0,41	0,41	0,41
Fevereiro/2007	0,41	0,39	0,39	0,39	0,38	0,39
Março/2007	0,41	0,42	0,42	0,42	0,42	0,42
Abril/2007	0,42	0,41	0,41	0,41	0,41	0,41
Maiο/2007	0,42	0,42	0,42	0,42	0,42	0,43
Junho/2007	0,42	0,43	0,43	0,42	0,43	0,42

Fonte: Dados de pesquisa.

**Tabela 11** - Poder de Previsão dos Preços pelos Modelos no Período de Janeiro de 2006 a Junho de 2007

(em %)

Mês	ARIMA	SARIMA	ARCH	GARCH	TARCH
Janeiro/2006	6,25	6,25	6,25	6,25	6,25
Fevereiro/2006	-3,03	-3,03	-3,03	-6,06	-3,03
Março/2006	3,13	3,13	3,13	6,25	3,13
Abril/2006	0,00	0,00	0,00	-3,13	0,00
Maiο/2006	0,00	0,00	0,00	0,00	0,00
Junho/2006	3,13	3,13	0,00	3,13	0,00
Julho/2006	0,00	0,00	0,00	-3,13	0,00
Agosto/2006	-3,03	-3,03	3,03	0,00	-3,03
Setembro/2006	-2,94	-2,94	2,94	-2,94	0,00
Outubro/2006	-5,41	-5,41	5,41	-5,41	-5,41
Novembro/2006	-2,56	-2,56	2,56	-2,56	0,00
Dezembro/2006	0,00	0,00	0,00	-2,50	2,50
Janeiro/2007	2,56	5,13	5,13	5,13	5,13
Fevereiro/2007	-4,88	-4,88	-4,88	-7,32	-4,88
Março/2007	2,44	2,44	2,44	2,44	2,44
Abril/2007	-2,38	-2,38	-2,38	-2,38	-2,38
Maiο/2007	0,00	0,00	0,00	0,00	2,38
Junho/2007	2,38	2,38	0,00	2,38	0,00
EPPM	2,45	2,59	2,29	3,39	2,25
CDT	0,015	0,015	0,015	0,020	0,015

Fonte: Dados de pesquisa.

delos ARIMA e SARIMA, como foi evidenciado pelo critério de avaliação Erro Percentual de Previsão (EPP). Em termos médios, o critério de avaliação Erro Percentual de Previsão Médio (EPPM) também sugere melhores previsões para os modelos TARCH e ARCH, respectivamente, embora pelo critério Coeficiente de Desigualdade de Theil (CDT) não haja diferença entre os modelos ARCH, TARCH, ARIMA e SARIMA.

Além disso, os modelos auto-regressivos com heterocedasticidade condicional ARCH, GARCH e TARCH estimados evidenciaram que a série de preços do trigo possui uma volatilidade persistente a choques ao longo do tempo, indicando que choques de aumento ou queda nos preços implicam intensa volatilidade, a qual, de acordo com o modelo TARCH, é regida por movimentos assimétricos, embora não ocorra o efeito alavancagem na série, em que o preço do trigo não possui maior volatilidade durante a queda do preço do que na alta.

Em síntese, todos os modelos podem ser utilizados como mecanismos de apoio à tomada de decisão na comercialização do trigo no Estado do Paraná, visando diminuir seus riscos e elevar suas margens de retorno, visto que os modelos tiveram uma alta *performance* nas previsões de preços do trigo, sendo eficazes ao prever com pequena margem de erro o preço do mês que está por vir.

## LITERATURA CITADA

- BITENCOURT, M. B. **Impactos dos acordos da Rodada do Uruguai, Mercosul, ALCA e rodada do milênio na triticultura brasileira - aplicação do modelo GTAP**. 2000. 113 p. Dissertação (Mestrado em Economia Rural) - Universidade Federal de Viçosa.
- BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. **Journal of Econometrics**, v. 31, p. 307-327, 1986.
- BOX, G. E. P.; JENKINS, G. M. **Time series analysis: forecasting and control**. New York: Holden Day, 1976. 575 p.
- \_\_\_\_\_; \_\_\_\_\_. REINSEL, G. **Time series analysis: forecasting and control**. New Jersey: Prentice Hall, 1994. 598 p.
- BRESSAN, A. A.; LIMA, J. E. **Modelos de previsão de preços aplicados aos contratos futuros de boi gordo na BM&F**. Disponível em: <www.face.ufmg.br/novaeconomia/sumarios/v12n1/v12n1bressan.pdf>. Acesso em: 26 nov. 2008.
- COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Central de informações agropecuárias**. Disponível em: <http://www.conab.gov.br>. Acesso em: 1 fev. 2008.
- ENDERS, W. **Applied econometric time series**. New York: John Wiley, 1995. 433 p.
- ENGLE, R. F. Autoregressive conditional heteroscedasticity with estimates of the variance of UK inflation. **Econometrica**, v. 50, n. 4, p. 987-1008, 1982.
- GUJARATI, D. N. **Econometria básica**. São Paulo: Makron Books, 2000. 846 p.
- INSTITUTO DE PESQUISA ECONÔMICA APLICADA - IPEA. **Ipeadata - série histórica**. Disponível em: <www.ipeadata.gov.br>. Acesso em: 3 nov. 2007.
- MACKINNON, J. G. Numerical distribution functions for unit root and cointegration tests. **Journal of Applied Econometrics**, v. 11, p. 601-618, 1996.
- SILVA, W. S.; SAFADI, T.; CASTRO JÚNIOR, L.G. de . Uma análise empírica da volatilidade do retorno de commodities agrícolas utilizando modelo ARCH: os casos do café e da soja. **Revista de Economia e Sociologia Rural**, Rio de Janeiro, v. 43, n. 1, p. 119-134, jan./mar. 2005.
- TWEETEN, L. G. **Foundations of farm policy**. 2. ed. Nebraska: University of Nebraska Press, 1979. Caps. 6-7.
- ZAKOIAN, J. M. Threshold heteroskedastic models. **Journal of Economics Dynamics and Control**, v. 18, p. 931-944, 1994.

Recebido em 23/10/2007. Liberado para publicação em 24/03/2007.