

**APLICAÇÃO DE MODELOS ARIMA EM SÉRIES DE PREÇOS DE SOJA NO
NORTE DO PARANÁ**

**ARIMA MODELS APPLICATION ON SOYBEAN PRICE SERIES IN THE NORTH
OF PARANA STATE**

ISRAEL JOSÉ DOS SANTOS FELIPE¹

Recebido em Agosto de 2012. Aceito Outubro em 2012.

¹ Mestrando em Administração - PPGA – UFRN, Especialista em Administração - israeljfelipe@gmail.com

APLICAÇÃO DE MODELOS ARIMA EM SÉRIES DE PREÇOS DE SOJA NO NORTE DO PARANÁ

RESUMO

Este estudo tem por objetivo analisar a série de preços diária da soja do Norte do Paraná que compreende o espaço temporal dos anos de 2000 (a partir de janeiro) a 2011 (até outubro) e descrever seu comportamento com previsões a curto prazo. Ou seja, verificar se a dinâmica temporal da variável é melhor explicada por um processo: Autorregressivo de ordem p , Média móvel de ordem q ; Autorregressivo e Média móvel de ordem p,q ; Autorregressivo, Integrado e Média móvel de ordem p,d,q ; ou ARIMA sazonal de ordem $(p,d,q), (P,D,Q)$. Para responder a tal questionamento foi utilizada a metodologia Box e Jenkins (1976). A manipulação dos dados foi baseada na análise gráfica e em testes estatísticos da própria metodologia, através da qual, observou-se que o modelo ARIMA (5,0,0) ou simplesmente AR (5), respondeu como o melhor modelo dentre o conjunto de modelos testados para prever o preço da soja.

PALAVRAS-CHAVE: Modelos ARIMA. Preços da soja. Séries temporais.

ARIMA MODELS APPLICATION ON SOYBEAN PRICE SERIES IN THE NORTH OF PARANA STATE

SUMMARY

This paper aims at analysing daily price list of soybean in the North of Parana state from January, 2000 to October, 2011, describing its behavior within a short term forecast. It was observed if the variable time dynamics would be better explained by an order autoregressive process p , order moving average q ; autoregressive and order moving average p, q ; autoregressive, integrated and order moving average p, d, q ; or order ARIMA seasonal $(p, d, q), (P, D, Q)$. Box and Jenkins (1976) methodology was used. Data were analysed based on graphics and on the methodology statistical tests through which it was observed that ARIMA model (5,0,0) or simply AR (5) showed better response as the best model among the tested series to forecast soybean price.

KEY WORDS: ARIMA models. Soybean prices. Time series

1. INTRODUÇÃO

Nos últimos anos, o Brasil vem se apresentando como país destaque no fornecimento e na comercialização de bens agrícolas. A sua lista de exportações abrange desde produtos agrícolas até produtos de maior valor agregado. Neste cenário, os bens de primeira ordem, ou seja, primários, tornam-se mais evidentes na composição da receita advinda do setor de exportação nacional.

Estes bens primários que são classificados como commodities angariam maior relevância econômico-financeira na formação do Produto Interno Bruto (PIB). Assim, o *glycine max*, ou simplesmente, feijão de soja, surge como um dos mais antigos produtos agrícolas comercializado.

Atualmente a soja domina tanto o mercado de proteína vegetal quanto o de óleo comestível. De acordo com Klaus (2005), o óleo surgiu como subproduto do processamento do farelo de soja e tornou-se um dos líderes mundiais no mercado de óleos.

O cultivo da soja teve seu auge produtivo mais precisamente na Região Sul, sobretudo nos Estados do Rio Grande do Sul e Paraná, a partir da década de 80. Sua cultura estendeu-se para a Região Centro-Oeste, principalmente para os Estados de Mato Grosso e Mato Grosso do Sul.

De acordo com a Emater (2012), o consumo mundial estimado de soja gira em torno de 254,90 milhões de toneladas e as exportações estão estimadas em 90,89 milhões de toneladas. Os EUA participam com aproximadamente 83,17 milhões de toneladas, cerca de 34% da produção mundial. Já o Brasil, ainda de acordo com Emater, tem 40,6% de participação no comércio mundial. Devido a enorme quantidade de área apropriada para o cultivo da soja e da não exploração de muitas delas ou das zonas de fronteiras agrícolas não definidas, o Brasil figura neste âmbito como um dos principais países produtores e exportadores da *commodity* soja.

O caráter exportador desta *commodity* confere à soja, de acordo com Margarido e Sousa (1998), uma forte dependência do mercado internacional, principalmente, dos preços cotados na *Chicago Board of Trade* (CBOT).

Entre os anos de 1990 a 1995, o preço desta *commodity* foi influenciado pelo preço da CBOT, embora se tenha evidências que não houve transmissão integral (MARGARIDO; SOUSA, 1998). Vale a pena ressaltar que são inúmeros os fatores que apresentam influência sobre a formação de preço da soja, mas, dentre eles, podem ser citados: a taxa de câmbio e o preço futuro da soja na Bolsa de

Mercado e Futuros de São Paulo (BM&F, 2011).

Diante do exposto, este artigo visa à aplicação de modelos ARIMA (Autorregressivos Integrados de Médias Móveis) nos preços de comercialização da soja do Norte do Paraná com a finalidade de auxiliar os produtores e empresários na comercialização dessa *commodity*.

2. MODELOS BOX E JENKINS

Uma série temporal ou série histórica pode ser entendida como uma sequência de dados obtidos em intervalos

regulares de tempo durante um período determinado. Para a análise de uma série temporal, inicialmente deve-se modelar o fenômeno estudado, sendo que, a partir deste ponto, pode ser feita a descrição do comportamento da série, as suas estimativas e finalmente a avaliação dos fatores que influenciam no comportamento da série, tendo em vista a definição da relação causa e efeito.

De acordo com Yin (2001), a sequência para a determinação do modelo da família ARIMA que melhor representa a série que poderá ser utilizado para fazer as previsões é segundo a Figura 1:

Figura 1 – Modelo para fazer previsões



Fonte: Adaptado de Yin (2001).

Os modelos ARIMA são amplamente utilizados para casos e estudos de preços. Suas construções se baseiam em modelos estatísticos lineares, em que as séries temporais envolvidas na análise são obtidas por um processo determinístico ou estocástico, cuja natureza poderá ser representada por meio de um modelo matemático.

Sáfadi (2004) afirma que é importante ressaltar que, para a aplicação dos modelos de Box e Jenkins, é

necessário que a série temporal em estudo seja estacionária, ou de outro modo, não apresente tendência ou sazonalidade. Para um bom ajuste do modelo, faz-se necessária a utilização de técnicas em que a estrutura residual forme um *white noise* (ruído branco), ou seja, o resíduo seja uma variável aleatória independente e identicamente distribuída.

Outra informação relevante é que o modelo básico de um processo estocástico é a sequência de ruídos brancos, ou seja,

variável aleatória independente com média zero e variância constante. É sabido que quando não apresenta ruído branco, um modelo apresenta dependência nos valores passados e tende a ser autocorrelacionado. A autocorrelação indicará que para a análise da série de preços há modelos que não são adequados para realizar previsões mais precisas.

2.1 Processo de estimação do modelo ARIMA

Dentre as classes de modelos propostos por Box e Jenkins (1976), será destacado, neste artigo, o ARIMA, que pode ser representando da seguinte forma:

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \dots + \beta_q \varepsilon_{t-q} \quad (1)$$

Nesta equação, o termo α_0 representa uma constante no modelo estimado, α_1 até α_p são parâmetros que ajustam os valores passados de y_t do instante imediatamente anterior até o mais distante representado por p . Os valores de ε , ou seja, o componente errático da série representa uma sequência de choques aleatórios e independentes uns dos outros, ε_t é uma porção não controlável do modelo é chamado comumente de ruído branco, se a série apresenta a não estacionariedade. Os parâmetros β_1 até β_q possibilitam escrever a série em função dos choques passados. Em geral, cada ε_t é considerado

como tendo distribuição normal, média zero, variância constante e não correlação. Em termos estatísticos, considerando-se que $E[x]$ denota a média teórica do valor de x , a sequência ε_t é considerada um processo ruído branco se para cada período de tempo t tivermos:

- (i) $E[\varepsilon_t] = E[\varepsilon_{t-1}] = \dots = 0$, Média zero;
- (ii) $E[\varepsilon_t^2] = E[\varepsilon_{t-1}^2] = \dots = \sigma^2$, variância constante;
- (iii) $E[\varepsilon_t \cdot \varepsilon_{t-s}] = E[\varepsilon_{t-j} \cdot \varepsilon_{t-j-s}] = \dots = 0$, covariância nula para todo valor de s .

A equação (1) representa um modelo denominado como Autorregressivo integrado de média móvel, ou simplesmente ARIMA. Sua equação pode ser escrita também no seguinte formato: $y_t = \alpha_0 + \sum_{i=1}^p \alpha_i y_{t-i} + \sum_{i=0}^q \beta_i \varepsilon_{t-i}$ sendo $\beta_0 = 1$. O termo modelo autorregressivo é utilizado quando se pode escrever uma série temporal na forma $y_t = \alpha_0 + \sum_{i=1}^p \alpha_i y_{t-i} + \varepsilon_t$, ou seja, a série y_t é escrita a partir dos seus valores passados. Transcrevendo a série em termos de choques aleatórios, tem-se o modelo de média móvel, ou seja, $y_t = \sum_{i=0}^q \beta_i \varepsilon_{t-i}$, onde $\beta_0 = 1$.

Se considerarmos a série, $y_t = \alpha_0 + \alpha_1 y_{t-1} + \varepsilon_t$, quando $\alpha_0 = 0$ e $\alpha_1 = 1$, o modelo será conhecido como passeio aleatório ou *random walk*, uma das características desse modelo é violar a condição de estacionariedade.

Um modelo é estacionário se para todo t e $t-s$ tivermos: (i) $E[y_t] = E[y_{t-s}] = \mu$, média constante; (ii) $E[(y_t - \mu)^2] = E[(y_{t-s} - \mu)^2] = \sigma_y^2$, variância constante; (iii) $E[(y_t - \mu)(y_{t-s} - \mu)] = \gamma_s$, covariância constante.

Na maioria das vezes, para transformar uma série estacionária precisa-se utilizar um recurso chamado de diferenciação, através do uso do operador Δ , sendo que $\Delta_j^d = (1 - L^j)^d$ e $L^j y_t$ idêntico a $(\equiv) y_{t-j}$. Quando y_t é uma série temporal $I(d)$ e depois de diferenciar d vezes ela pode ser modelada usando um modelo $AR(p)$, este modelo para y_t pode ser escrito como (FRANSES, 1998):

$$\Delta_1^d y_t - \phi_1 \Delta_1^d y_{t-1} - \dots - \phi_p \Delta_1^d y_{t-p} = \varepsilon_t, t=p+d, p+d+1, \dots, n. \quad (2)$$

O modelo representado por (2) normalmente é abreviado por $ARI(p,d)$, ou seja, Autorregressivo de ordem p e integrado de ordem d . Quando uma série temporal apresenta uma tendência provavelmente ela poderá ser representada por um modelo integrado ARI , $ARIMA$ ou IMA .

2.2 Teste de Estacionaridade

Segundo Arêdes e Pereira (2008), o teste mais simples para analisar a

estacionaridade em séries temporais é dado pela obtenção dos coeficientes de autocorrelação e autocorrelação parcial, a partir dos quais são construídos os respectivos correlogramas: FAC (função de autocorrelação) e $FACP$ (função de autocorrelação parcial), que por sua vez representam as inspeções gráficas das defasagens. Este correlograma delimita um intervalo de confiança para os coeficientes no qual as estatísticas da FAC e $FACP$ devem variar e é definido por:

$$IC(95\%) = 0 \pm 1,96 \cdot (1/\sqrt{n}),$$

onde n = tamanho da amostra.

Gujarati (2000) concluiu que os coeficientes de autocorrelação e autocorrelação parcial fora desse intervalo, exceto para a defasagem um, são estatisticamente diferentes de zero, sugerindo não estacionaridade da série.

Outro tipo de teste amplamente utilizado para a verificação da estacionaridade é o Dickey-Fuller (DF), que testa a hipótese nula da existência de raiz unitária na série. Caso esta hipótese não seja rejeitada, a série possuirá raiz unitária, portanto, não será estacionária. Para evitar o problema da autocorrelação dos resíduos, recomenda-se a utilização do teste ADF (Dickey-Fuller Aumentado), que engloba a equação das defasagens para eliminação do problema de autocorrelação dos resíduos.

2.3 Teste de Autocorrelação

A estatística Ljung-Box (1978) é muito utilizada para diagnosticar se a série temporal possui autocorrelação. Sua representação segue a seguinte lógica:

$$Q_{LB} = n(n+2) \sum_{k=1}^m (P_k^2 | n-k) \sim X_m^2$$

onde n , representa o número de observações e K representa o número de parâmetros estimados. Esta estatística de teste também segue uma distribuição Qui-Quadrado com $k-p-q$ graus de liberdade. A grande ênfase atribuída à estatística de Ljung-Box está no fato que esta metodologia possui as melhores propriedades para amostras finitas do que a estatística Box e Pierce (1970), mas ambas seguem a mesma interpretação.

De acordo com Sáfadi (2004) e Gujarati (2000), se o $Q_{Calculado} > Q_{Tabulado}$ para determinado nível de significância, não se aceita a hipótese nula (H_0) de que os resíduos não são autocorrelacionados. Porém isso implica em aceitar a hipótese, alternativa (H_1) de que pelo menos uma autocorrelação r_k é estatisticamente diferente de zero, desse modo, o erro não é ruído branco.

2.4 Critérios de seleção (penalizadores de modelos)

Os critérios de seleção com base na variância estimada mais utilizados são o AIC e o BIC, que podem ser definidos por:

$$\text{AIC (Akaike's Information Criterion): } AIC = T \ln(\text{SQR}) + 2n$$

$$\text{BIC (Bayesian Information Criterion): } BIC = T \ln(\text{SQR}) + n \ln(T)$$

onde: T é o tamanho da amostra; SQR é a soma dos quadrados dos resíduos e n é o número de parâmetros (MARCHEZAN, 2007).

Em linhas gerais, dentre os vários modelos apresentados, escolhe-se aquele que apresenta o menor *AIC* e *BIC*. Salienta-se também que a escolha deverá levar em consideração os modelos parcimoniosos, ou seja, aqueles que apresentam o menor número de parâmetros. Por fim, é recomendável que esses critérios sejam avaliados conjuntamente, pois são complementares e não excludentes.

Como neste artigo serão testados alguns conjuntos de modelos ARIMA, será escolhido apenas um deles, o qual representará significativamente a série original por meio de critérios penalizadores, neste caso o *AIC*.

3. PROCEDIMENTOS METODOLÓGICOS

A metodologia utilizada neste estudo, a ARIMA, parte do princípio de que os modelos econométricos podem ser desenvolvidos a partir da informação contida nos próprios dados. Essa metodologia foi desenvolvida inicialmente por Box e Jenkins (1976).

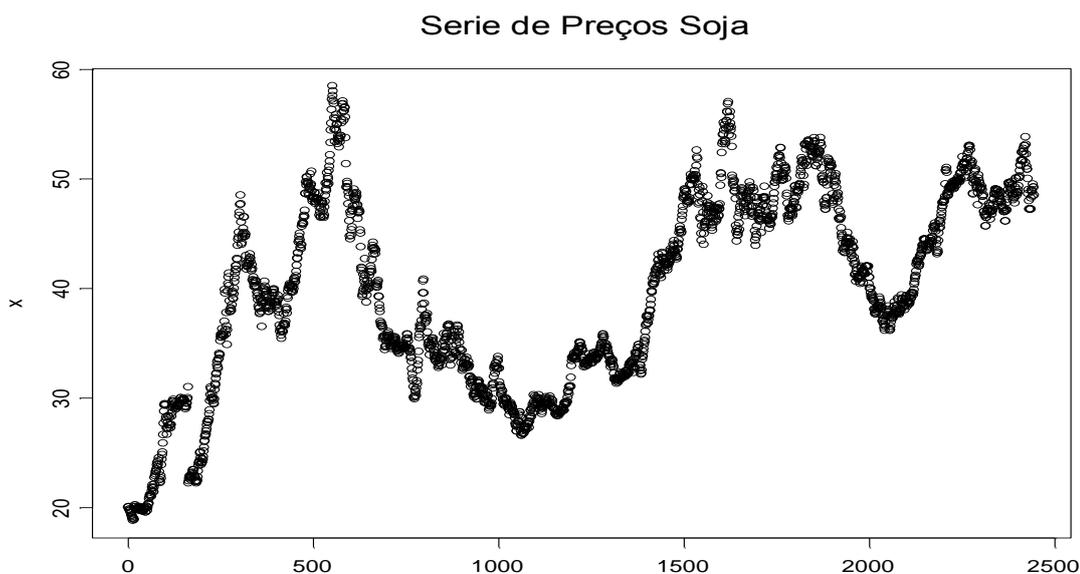
Os dados coletados referem-se aos preços diários da soja comercializada no Norte do Paraná, entre os períodos históricos de janeiro de 2010 a outubro de 2011, totalizando 2672 observações, obtidos por meio do banco de dados do site *Bloomberg* (2012).

Em resumo, foram feitos os seguintes procedimentos: a) Teste de estacionaridade (*ADF*); b) Verificação de autocorrelações residuais (*FAC* e *FACP*); c) Testes de significância para com o conjunto de modelos ARIMA encontrados; e) Aplicação dos critérios penalizadores (*AIC*) e, por fim, a verificação da qualidade do modelo para realizar previsão de preços.

Para a manipulação dos procedimentos estatísticos do presente estudo, foram utilizados neste estudo os seguintes softwares computacionais: Microsoft Excel 2010 e o S-Plus 8.0.

4. RESULTADOS

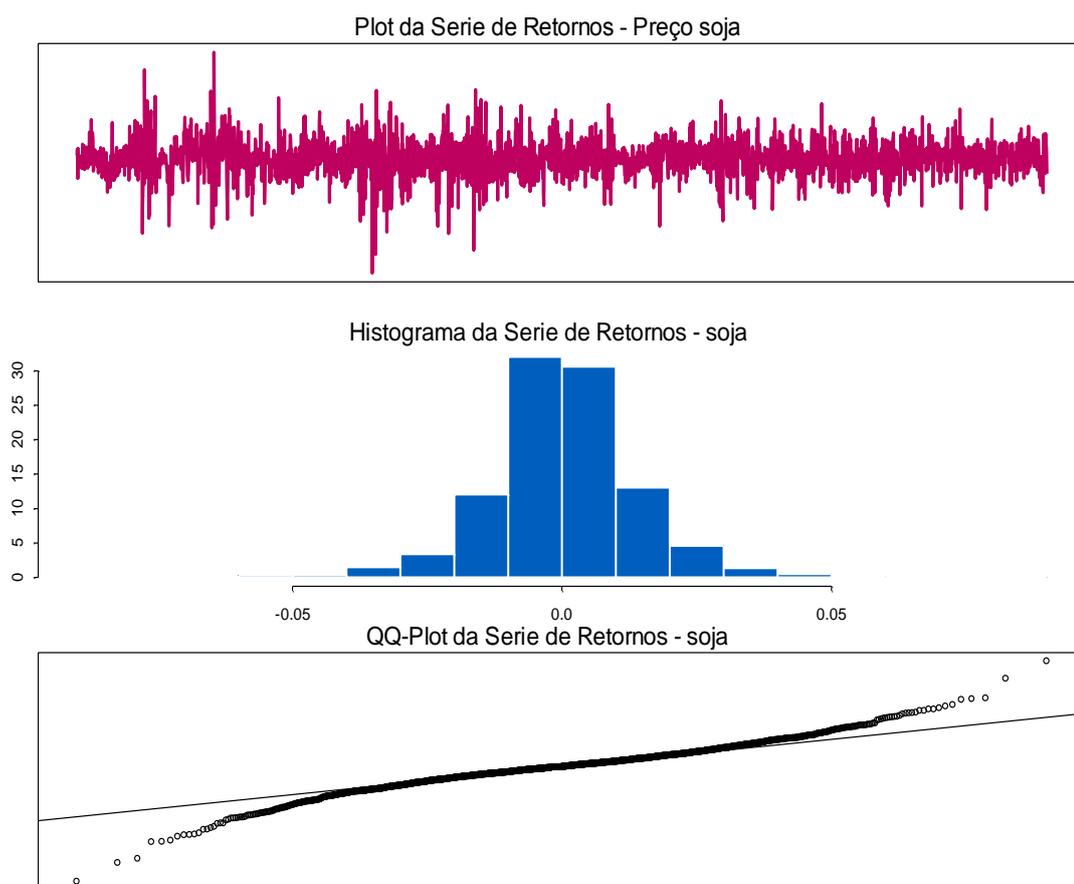
Figura 2 – Série índice de preços da soja do Norte do Paraná de janeiro de 2010 a outubro de 2011



Observa-se, na Figura 2, que os preços da soja do Norte do Paraná apresentam uma tendência não uniforme em seus preços, ou seja, em determinados instantes o preço sofre

diversas alterações temporais, o que demonstra que a série em estudo na realidade tem uma grande variabilidade, de modo que a mesma pode ser ponderada como não estacionária.

Figura 3 – Plot, Histograma e QQ- Plot da série de retornos da soja

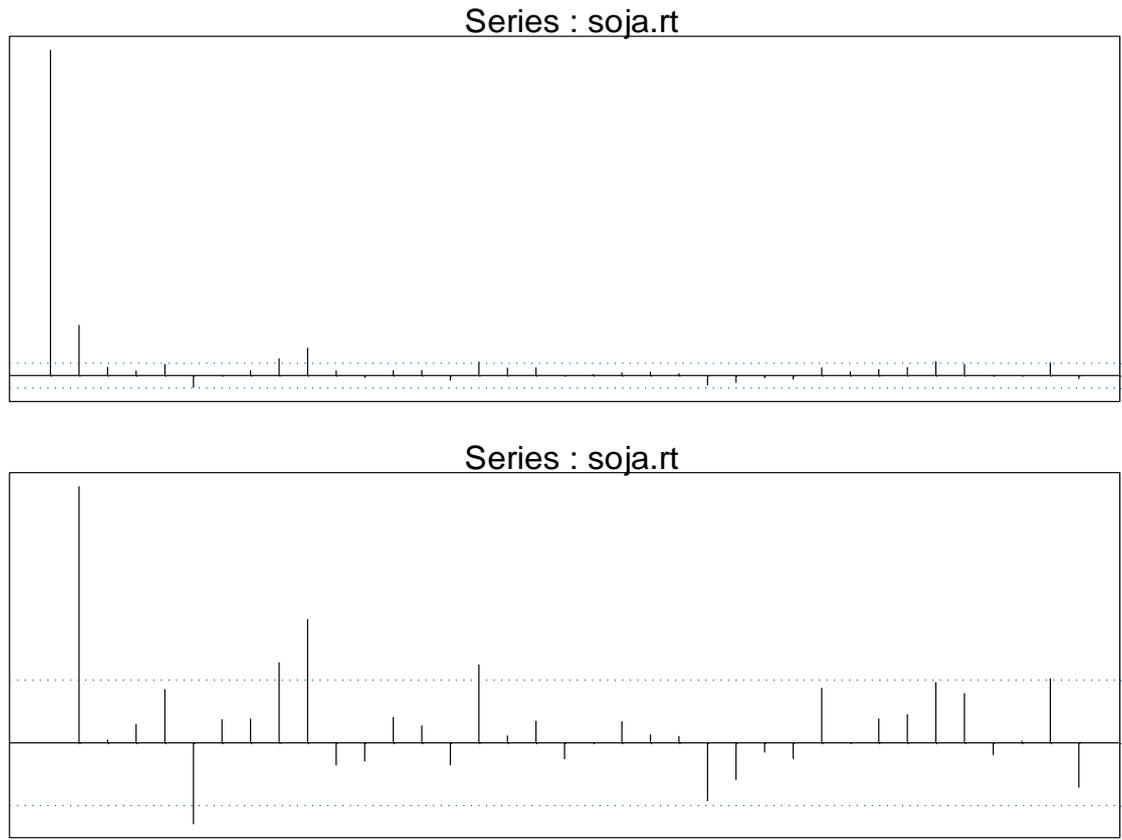


Para melhor entendimento do comportamento da série de preços da soja, foi criada uma série defasada (Figura 3), denominada de série de retornos - preço soja, obtida por:

$$\omega_t = \frac{y_t - y_{t-1}}{y_{t-1}}, \text{ onde } y_t \text{ é o preço de hoje da}$$

soja e y_{t-1} é o preço de ontem. Através dessa diferença, visualizam-se os retornos da série e, determinar a dependência temporal dos preços. Os gráficos contemplados na Figura (3) evidenciam o relacionamento e a variabilidade dos dados da *commodity* soja.

Figura 4 – Correlograma (FAC e FACP) das séries em estudo

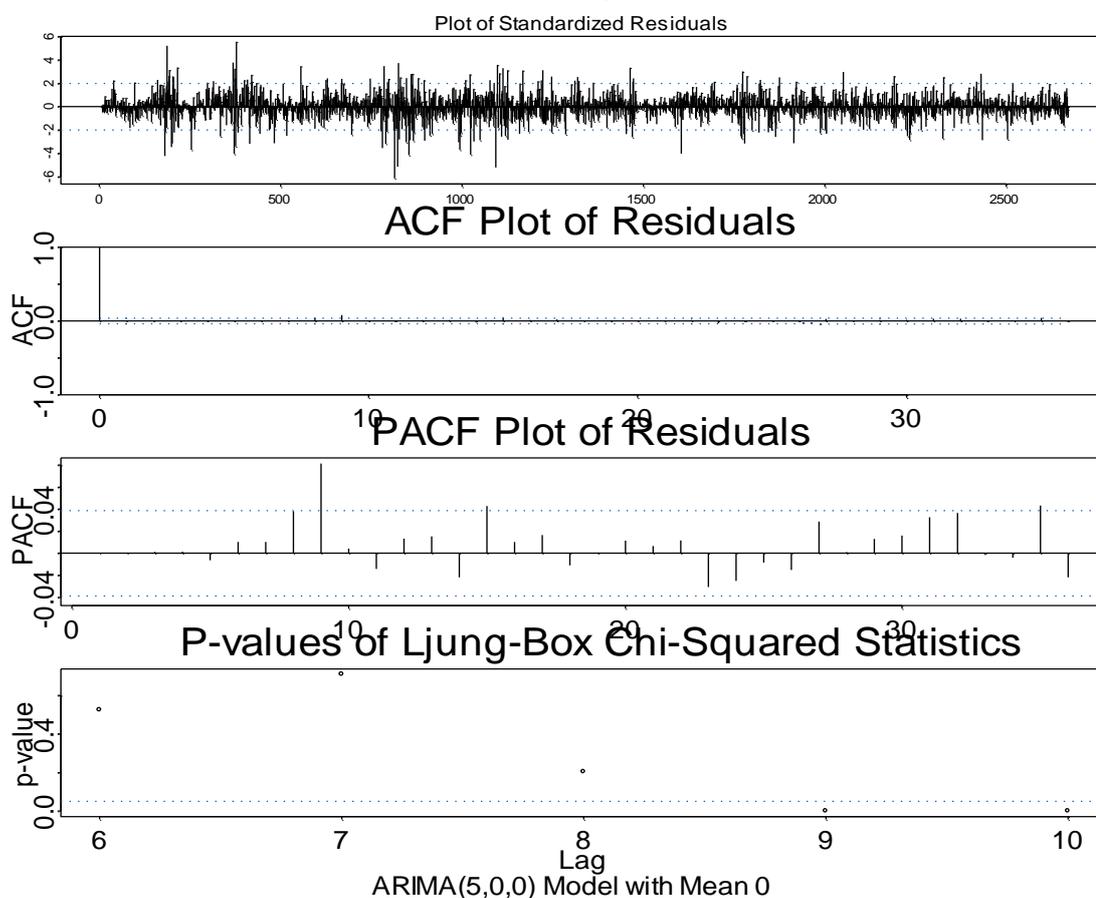


Analisando o correlograma expresso na Figura 4, percebe-se que a série primitiva de dados (2º gráfico) apresenta uma dependência temporal em relação aos dias observados na relação presente-passado. Já no 1º gráfico (série defasada), nota-se a presença estrutural da aleatoriedade nos

dados observados, pois se verifica pouca dependência temporal entre os preços na relação presente-passado da série em estudo, o que é fato essencial para a posterior descoberta acerca do modelo mais ajustado para a realização de previsões de preços do ativo soja.

Figura 5 – Correlograma dos resíduos da série de preços em estudo

ARIMA Model Diagnostics: soja.rt



De acordo com os modelos autorregressivos testados neste estudo (Figura 5), o que mais se ajustou em termos de significância estatística foi o ARIMA (5,0,0), ou seja, o modelo AR(5) sem diferenciação e sem média móvel, onde o AR(5), indica o número de termos autorregressivos.

Através aplicação desse modelo, obteve-se uma maior aleatoriedade no

comportamento dos preços, quase não se notou a presença da autocorrelação nos dados (FAC), verificou-se também baixa autocorrelação parcial (FACP) e os valores *p* da série em estudo ficaram abaixo de 5% de significância estatística, indicando um forte grau de ajuste do modelo escolhido (verificar tabela 1 e tabela 2).

Tabela 1- *Output* dos Modelos ARIMA testados no *S-Plus*

Call: arima.mle(x = soja.rt, model = list(ar = c(0.1, 0.1, 0.1, 0.1, 0.1)))

Method: Maximum Likelihood

Model : 5 0 0

Coefficients:

AR : 0.15724 0.00065 0.00671 0.04053 -0.04903

Variance-Covariance Matrix:

	<i>ar(1)</i>	<i>ar(2)</i>	<i>ar(3)</i>	<i>ar(4)</i>
<i>ar(1)</i>	3.741921e-004	-5.823551e-005	-1.193795e-007	-2.503579e-006
<i>ar(2)</i>	-5.823551e-005	3.828503e-004	-5.829929e-005	2.663250e-007
<i>ar(3)</i>	-1.193795e-007	-5.829929e-005	3.828336e-004	-5.829929e-005
<i>ar(4)</i>	-2.503579e-006	2.663250e-007	-5.829929e-005	3.828503e-004
<i>ar(5)</i>	-1.231061e-005	-2.503579e-006	-1.193795e-007	-5.823551e-005

ar(5)

ar(1) -1.231061e-005

ar(2) -2.503579e-006

ar(3) -1.193795e-007

ar(4) -5.823551e-005

ar(5) 3.741921e-004

Optimizer has converged

Convergence Type: relative function convergence

AIC: -15.351,52(Critério de Informação penalizador)

Através de uma rápida inspeção nos valores do *output* do programa *S-Plus* acerca do conjunto de modelos ARIMA testados (Tabela 1), pode-se visualizar que o modelo AR(5) ou ARIMA incompleto, apresenta-se com a melhor matriz de covariância, ou seja, os coeficientes mais significantes estatisticamente.

Como forma de comprovação acerca dos resultados estatísticos, a tabela 2, demonstra os valores do Critério penalizador *AIC*, cuja finalidade é descrever o modelo mais parcimonioso, ou de outro modo, o que envolva o menor número de parâmetros possíveis a serem estimados e que explique bem o comportamento da variável resposta.

Tabela 2 – Valores dos AIC's encontrados

AR 1	AR 2	AR 3	AR 4	AR 5
10.000,00	-15.381, 61	-15.380,17	-15.378,21	-15.382,54
-15.376,64	-15.374,67	-15.375,57	-15.370,20	-15.373,36
-15.367,16	-15.367,99	-15.365,24	-15.361,43	-15.370,02
-15.360,23	-15.358,24	-15.358,91	-15.361,22	-15.361,70
-15.355,94	-15.356,85	-15.352,61	-15.350,39	<u>-15.351,52</u>

Já o Plot da previsão (ver Figura 6) realizada nos preços apresentou um forte ajuste em relação à tendência da série de preços, o que pode se comprovado a seguir, onde a média de acerto da previsão

está representada pelos pontos em destaque, que por sua vez denotam um comportamento cíclico em torno da média das expectativas futuras da previsão.

Figura 6 – Plot da Previsão dos preços

Plotting the forecasts

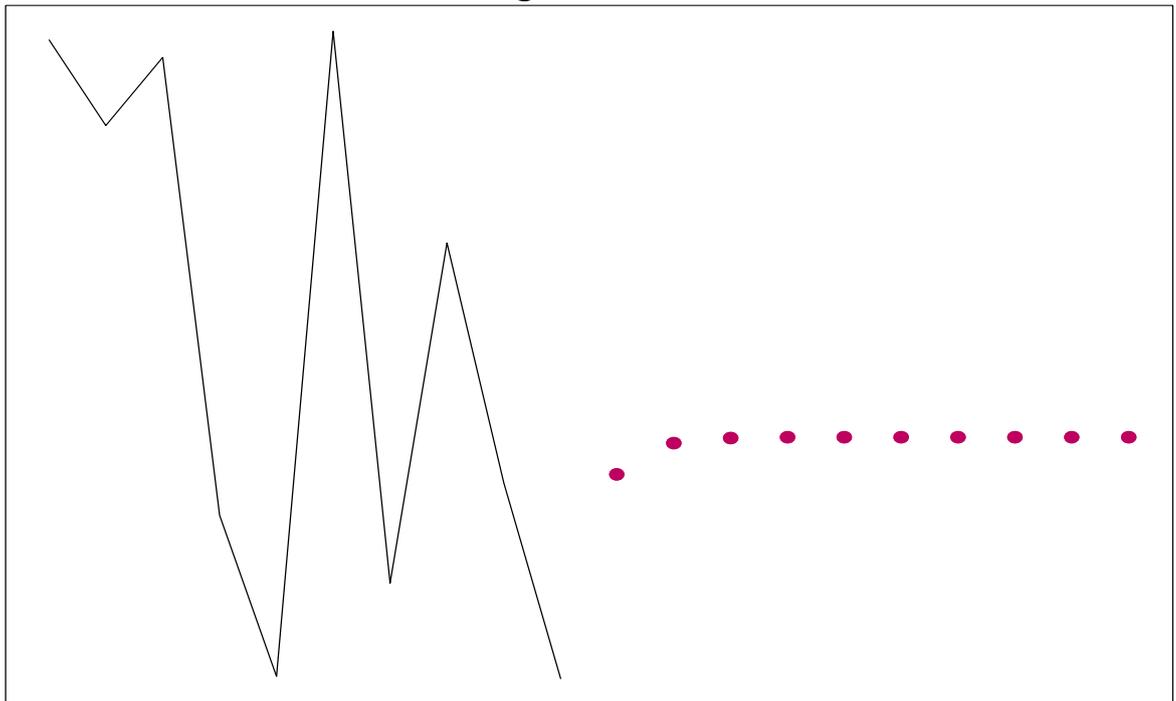
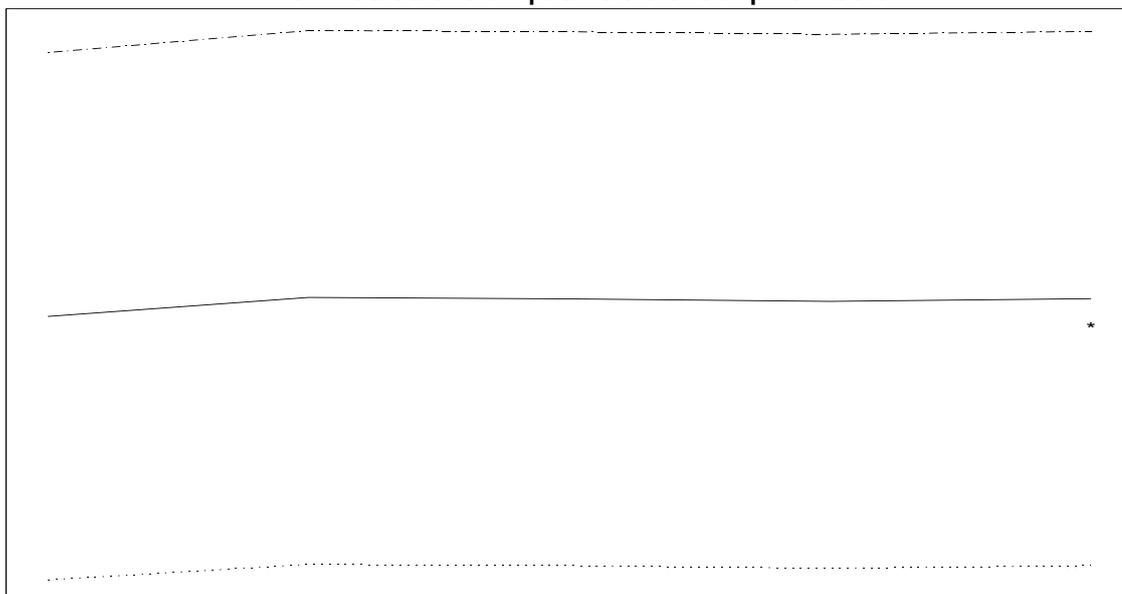


Figura 7 – Verificação gráfica do ajuste do modelo e da qualidade da previsão
Tekhne e Logos, Botucatu, SP, v.3, n.3, Novembro. 2012

Verificacao da qualidade da previsao



Para comprovar as expectativas em torno da qualidade do modelo escolhido a fim de se fazer a previsão de preços, foi feito o teste de verificação da qualidade da previsão (Figura 7), onde se pôde verificar que a previsão feita através do modelo ARIMA (5,0,0) revelou-se ser crescentemente positiva e bem próxima da

realidade da série de preços da soja do Norte do Paraná, cujo valor ficou em R\$ 47,28. Esse valor foi obtido por meio do método de previsão um passo a frente, considerando-se o próximo mês como período de referência.

5. CONCLUSÃO

Através da aplicação da metodologia de séries temporais desenvolvida por Box e Jenkins (1976), o pesquisador pode modelar uma série que tenha comportamento temporal presente nos dados coletados e escolher o melhor modelo do ponto de vista de significância estatística entre um conjunto de possíveis modelos concorrentes. Com a manipulação deste ferramental estatístico, tornou-se possível a escolha ou sugestão de um modelo matemático representativo para os preços da soja do Norte do Paraná.

Para modelar a série de preços utilizou-se o modelo Autorregressivo Integrado de Médias Móveis [ARIMA(5,0,0)] com um nível de defasagem (chamado de retorno dos preços da soja) que, por sua vez, respondeu aos testes econométricos com maior robustez e precisão estatística.

Por fim, vale salientar que este estudo deu ênfase a apresentação e manipulação da metodologia Box e Jenkins (1976), servindo de base para a realização de outros estudos *a posteriori*. Além disso, foi possível concluir que essa metodologia satisfaz os requisitos para a escolha do modelo mais apropriado para fazer previsões e representar o comportamento

dos preços da soja do Norte do Paraná no período de janeiro de 2000 a outubro de 2011.

REFERÊNCIAS

ARÊDES, A. F.; PEREIRA, M.W. G. Potencialidade da utilização de modelos de séries temporais na previsão no preço do trigo no estado do Paraná. **Revista de Economia Agrícola**, São Paulo, v. 55, n. 1, p. 6376, jan./jun., 2008.

BM&F. BOVESPA. **Contratos futuros de soja: vencimentos**. Disponível em: <http://www.bmf.com.br/bmfbovespa/pages/contratos1/Agropecuarios/pdf/Soja_Fut_Liquidacao_Financeira.pdf>. Acesso em: 20 set. 2012.

BOX, G. E. P.; JENKINS, G. M. **Time series analysis forecasting and control**. Edição revisada. San Francisco: Holden Day, 1976.

BOX, G. E. P.; PIERCE, D. A. Distribution of residual autocorrelations in autoregressive-integrated moving average time series models. **J. Am. Stat. Assoc.**, New York, v. 65, n. 332, p. 1509-1526, 1970.

EMATER. **Instituto de Assistência Técnica e Rural**. Disponível em: <<http://www.emater.go.gov.br/w/3446>> Acesso em: 20 set. 2012.

ENDERS, W. **Applied econometric time series**. New York: John Wiley, 1995.

GUJARATI, D.N. **Econometria básica**. São Paulo: Makron Books, 2000.

KLAUS, W. **Soja sua fantástica história**. Porto Alegre: Imprensa Livre, 2005.

MARCHEZAN, A. **Previsão do preço dos principais grãos do Rio Grande do Sul.** Monografia de Especialização em Estatística e Modelagem Quantitativa, UFSM, Santa Maria/RS, 2007.

MARGARIDO, M. A. & SOUSA, E. L. de. Formação de preços da soja no Brasil. **Anais do 36º Congresso Brasileiro de Economia e Sociologia Rural**, p. 773-784, 1998.

LJUNG, G. M. & BOX, G. E. P. On a measure of lack of fit in time series models. **Biometrika**, v. 65, p. 297-303, 1978.

RUSSO, S. L. **Gráficos de controle para variáveis não-conformes autocorrelacionadas.** Tese de Doutorado. Programa de Pós-graduação em Engenharia de Produção, UFSC, Florianópolis/SC, 2002.

SÁFADI, T. **Uso de séries temporais na análise de vazão de água na represa de Furnas.** Ciência Agrotécnica, Lavras, v.28, n.1, p.142-148, jan/fev, 2004.

SOUZA, G. P.; SAMOHYL, R.W; MIRANDA, R.G. **Modelos simplificados de previsão empresarial.** Rio de Janeiro: Editora Ciência Moderna, 2007.

YIN, Robert K. **Estudo de caso: planejamento e métodos.** 2. ed. Porto Alegre: Bookman, 2001.