

Aplicação do modelo arima para previsão do preço da commodity milho

Application of The ARIMA Model to Forecast the Price of the Commodity Corn

Carlos Gonçalves Cas¹ - Universidade do Estado do Rio de Janeiro

RESUMO O presente trabalho se propõe a analisar o comportamento dos preços médios recebidos pelo produtor da commodity milho brasileira. Para tanto, procurou-se realizar uma previsão para os preços deste produto a partir da metodologia ARIMA. O período analisado pela modelagem compreende março de 2004 a março de 2016. O modelo ARMA (1,2) estimado foi eficiente e apresentou projeção satisfatória para previsão dos preços do milho no mercado brasileiro. Os resultados obtidos fornecem uma ferramenta de análise para o mercado desta commodity, na medida em que demonstram a tendência dos preços para um horizonte de curto prazo, servindo de auxílio à tomada de decisão de agentes que comercializam este bem.

Palavras-chave: Modelagem ARIMA. Commodity milho. Previsão.

ABSTRACT This study aims to analyze the behavior of the average price received by the producer for the Brazilian commodity corn. Therefore, we tried to perform a forecast for the price of this product using the ARIMA methodology. The period analyzed by modeling was between March 2004 and March 2016. The ARMA (1.2) estimate was efficient and showed satisfactory projection for predicting corn prices in the Brazilian market. The results provide an analysis tool for the market of this commodity, in that it shows the price trend along a short-term horizon, providing help to decision-making agents who commercialize this good.

Keywords: ARIMA modeling. Corn commodity. Forecast.

1. Rua São Francisco Xavier, 524, Maracanã, Rio de Janeiro, RJ, CEP: 20.550-013, carlos.silva@uerj.br

CAS, C. G. Aplicação do modelo arima para previsão do preço da commodity milho. **GEPROS. Gestão da Produção, Operações e Sistemas**, Bauru, Ano 13, nº 1, jan-mar/2018, p. 263-279.

DOI: 10.15675/gepros.v13i1.2040

1. INTRODUÇÃO

A cultura de milho se consolida na atualidade como a segunda maior atividade agrícola brasileira. Os dados da Companhia Nacional de Abastecimento (CONAB) demonstram que o cereal representou 41,43% de toda a produção de grãos do país na safra 2013/2014, com 80,05 milhões de toneladas produzidas.

No cenário mundial da produção agrícola, hoje o milho é o cereal mais produzido, sendo esperada 989,30 milhões de toneladas para a safra 2015/2016. A produção mundial concentra-se basicamente em três grandes produtores: EUA, China e Brasil, esses países representam 65,62% da produção mundial de milho. O Brasil se encontra na terceira posição no ranking de produtores e são aguardados 75,00 milhões de toneladas para a safra 2015/2016 de acordo com a CONAB.

No cenário brasileiro, o Estado do Mato Grosso destaca-se como um grande produtor da *commodity* desde a safra 2012/2013, e o município de Sorriso é considerado o maior produtor de cereal em âmbito nacional. Não obstante, das dez maiores cidades produtoras de milho no Brasil, seis se encontram em Mato Grosso, segundo dados do Instituto Brasileiro de Geografia e Estatísticas.

No que tange à comercialização e consumo do milho brasileiro, grande parte da produção é direcionada às exportações. De maneira geral grande parte desse milho é destinada à produção de rações que servirão como alimento de aves e suínos nos países importadores. Os principais importadores do milho brasileiro se encontram no oriente, destacando-se: Irã, Vietnã, Coreia do Sul, Japão e Taiwan. Os mecanismos dessa comercialização se dão principalmente pelo mercado à vista conhecido como *spot* ou mercado futuro com a participação de intermediários financeiros, no Brasil BM&FBOVESPA e CETIP.

O preço do milho é cotado internacionalmente, e a Bolsa de Mercadorias de Chicago- CME aparece como a principal referência para os preços internacionais dessa *commodity*. A escolha da Bolsa de Chicago como referência mundial se dá pela alta concentração da oferta e da demanda dos principais países produtores e importadores neste mercado.

Nesse contexto, este trabalho tem por objetivo avaliar a potencialidade da utilização de modelos de séries temporais na previsão de preços do milho, ou seja, poderão ser empregados no planejamento e comercialização das safras, gerando informações que darão suporte ao produtor em suas decisões.

Além desta introdução, o trabalho é composto por mais quatro partes. Na segunda parte, expor-se-á a revisão de literatura. Na terceira explicar-se-á o modelo ARIMA e suas propriedades teóricas. Na quarta apresentar-se-á a análise e discussão dos resultados obtidos. Na seção seguinte serão expostas as conclusões sobre o trabalho. Finalmente, apresentar-se-ão as referências bibliográficas utilizadas.

2. REVISÃO DE LITERATURA

Verificam-se inúmeros trabalhos relacionados à previsão dos preços de *commodities*, devido a sua importância no auxílio à tomada de decisões de produtores e investidores.

A modelagem ARIMA e a técnica de Box e Jenkins (1976) para previsão de séries temporais são metodologias amplamente utilizadas nesse tipo de trabalho.

O estudo de Souza et al.(2007) analisa a confiabilidade da metodologia Box & Jenkins, aplicando o modelo ARIMA na previsão do preço da madeira serrada pago as exportações do Estado do Paraná. Os autores procuram examinar a acuracidade desses métodos econométricos visando dar suporte e auxiliar na tomada de decisões por parte das empresas florestais. De acordo com os resultados, a metodologia foi capaz de formular um modelo estocástico com nível explicativo satisfatório para a série em estudo.

Lamounier e Leite (2007) procuram detectar a existência dos componentes estocásticos e/ou determinísticos de tendência, ciclo, e sazonalidade nos preços do mercado *spot* do café no Brasil. Os autores explicam que existem diversos métodos para a análise do componente sazonal em uma série de tempo, como: a análise visual do gráfico da série, os modelos de regressão linear com variáveis independentes binárias, e a utilização de métodos mais sofisticados como dos modelos de análise espectral, dos modelos de Box e Jenkins sazonais (SARIMA) e de alisamento sazonal.

A eficácia dos modelos de séries temporais na previsão dos preços de *commodities* é destaque nos estudos de Arêdes e Pereira (2008). Os autores procuraram avaliar a potencialidade da utilização de modelos de séries temporais na previsão de preços do trigo no Estado do Paraná. Os modelos de séries temporais estimados foram o ARIMA, o SARIMA, o ARCH, o GARCH e o TARCH. Os resultados evidenciaram que todos os modelos são eficazes na previsão do preço do trigo, dado que os preços previstos são próximos aos observados.

O trabalho de Marques et al.(2010) procurou apresentar e analisar projeções de produção, consumo, exportação e preço de exportação do café. As projeções das variáveis descritas foram geradas a partir da utilização dos modelos de séries temporais.

De acordo com os autores, os modelos ARIMA, formulados por Box e Jenkins (1976), seguem a proposição de que uma série temporal não-estacionária pode ser modelada a partir de diferenciações e da inclusão de um componente autoregressivo e de um componente média móvel.

Felipe (2012) analisou a série de preços da soja do Norte do Paraná de janeiro de 2000 a outubro de 2011. O autor procurou determinar o modelo que melhor explica a dinâmica temporal dos preços da soja, utilizando a metodologia Box e Jenkins (1976). Observou-se que dentre o conjunto de modelos testados para previsão do preço da soja, o melhor modelo foi o AR (5), ou seja, a série preços da soja do Norte do Paraná pode ser explicada por um processo autoregressivo de ordem cinco.

3. METODOLOGIA E DADOS

3.1. Testes de raiz unitária e sazonalidade

Para testar a estacionariedade das séries, serão utilizados neste trabalho, os testes ADF (Dickey – Fuller Aumentado) (1979 e 1981) e KPSS (Kwiatkowski, Phillips, Schmidt e Shin (1992), bem como o teste HEGY (2004) no sentido de verificar a existência de sazonalidade.

O teste de Dickey-Fuller Aumentado (ADF) consiste na estimação da seguinte Equação por Mínimos Quadrados Ordinários (MQO):

$$\Delta Y_t = \alpha + \beta t + \gamma Y_{t-1} + \sum_{i=1}^p \delta_i \Delta Y_{t-1} + \varepsilon_t \quad (1)$$

onde ΔY_t é o operador de diferenças ($Y_t - Y_{t-1}$), α é uma constante, β_t é a componente de γ tendência do modelo, γ é o coeficiente que permite testar a estacionariedade (se = 0, Y tem uma raiz unitária), p é o número defasados a incluir no modelo e ε_t é o termo de erro aleatório ou perturbação estocástica.

O teste KPSS [Kwiatkowski, Phillips, Schmidt e Shin (1992)], surgiu como uma forma de complementar a análise dos testes de raiz unitária tradicional, como teste ADF. Ao contrário do teste ADF, o teste KPSS, considera como hipótese nula que a série é estacionária, ou estacionária em torno de uma tendência determinística, contra a hipótese alternativa que um caminho aleatório está presente.

Para avaliar a existência ou não de sazonalidade na série dos preços do milho, serão utilizados os testes de Hylleberg, Engle, Granger e Yoo, conhecido como teste de HEGY (1990), uma vez que a sazonalidade é muito comum em séries temporais mensais. Este teste verifica a existência de raiz unitária sazonal e raiz unitária regular (não-sazonal / tendência estocástica). De acordo com Lütkepohl e Krätzig (2004), o teste para dados mensais é dado pelo seguinte modelo estimado por MQO (mínimos quadrados ordinários):

$$\begin{aligned} \Delta_{12}y_t = & \pi_1 y_{1,t-1} + \pi_2 y_{2,t-1} + \pi_3 y_{3,t-1} + \pi_4 y_{3,t-2} + \pi_5 y_{4,t-1} + \pi_6 y_{4,t-2} \\ & + \pi_7 y_{5,t-1} + \pi_8 y_{5,t-2} + \pi_9 y_{6,t-1} + \pi_{10} y_{6,t-2} + \pi_{11} y_{7,t-1} + \pi_{12} y_{7,t-2} + u_t + \varepsilon_t \end{aligned} \quad (2)$$

Para analisar sua significância estatística empregam-se as estatísticas t , bem como o teste F (para significância conjunta dos parâmetros) e seus valores críticos são apresentados por Franses (1990) e Franses e Hobijn (1997).

Segundo Lütkepohl e Krätzig (2004), o processo Y_t terá raiz unitária não sazonal na frequência zero (tendência estocástica), caso $\pi_1 = 0$; e terá raiz unitária sazonal, se ao menos um da ordem $\pi_i (i=2,3,\dots,12)$ for igual a zero.

3.2. Modelos univariados de série de tempo

Modelos univariados são aqueles em que os valores correntes de uma série de tempo são relacionados apenas com seus próprios valores passados ou com os valores correntes e passados dos resíduos da série temporal.

A combinação dos modelos auto-regressivos (AR) e de médias móveis (MA) resulta no modelo denominado ARMA. Assim, tratando-se de uma série temporal Y_t e considerando-se suas primeiras diferenças $Y_t = Y_t - Y_{t-1}$, com p defasagens para a variável e q para os erros aleatórios, pode-se expressar o modelo ARMA(p,q) da seguinte maneira:

$$Y_t = \mu + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (3)$$

O modelo ARIMA (p, d, q), onde p refere-se ao número de defasagens da série, d é a ordem de integração e q é o número de defasagens dos erros aleatórios. Portanto, utiliza-se os procedimentos sugeridos por Box e Jenkins (1976), cujas etapas são as seguintes:

- a) Identificação - Determina-se os valores apropriados de p, d e q e utiliza-se um correlograma apresentando as funções de autocorrelação parcial (FACP) e de autocorrelação simples (FAC), podendo determinar a ordem apropriada dos componentes AR e MA.
- b) Estimação - esta etapa vem após a identificação e consiste em estimar os parâmetros autoregressivos e de médias móveis. Verifica-se a significância estatística dos parâmetros sugeridos para o modelo.
- c) Verificação - Consiste em verificar se o modelo estimado ajusta-se adequadamente à série ou não e se os resíduos calculados apresentam ou não problemas de autocorrelação, bem como existência de heterocedasticidade. Os critérios de informação de Akaike e de Schwarz ajudam neste diagnóstico, bem como a utilização da estatística Q de Ljung-Box. O teste Q é usado para testar se um conjunto de autocorrelações de resíduos é ou não estatisticamente diferente de zero. A estatística Q conterá aproximadamente uma distribuição X^2 com K-p-q graus de liberdade.
- d) Previsão - O modelo ARIMA estimado pode ser utilizado nas previsões, tornando-se possível calcular previsões de Y_t para n períodos seguintes, desde que sejam conhecidos Y_{t-1} e Y_t .

3.3. Dados

O período da análise deste trabalho estende-se de março de 2004 a março de 2016, com periodicidade mensal. Os preços médios do milho foram extraídos no site AGROLINK, sendo os preços atualizados monetariamente para março de 2016 pelo Índice Geral de Preços – Disponibilidade Interna (IGP-DI) da Fundação Getúlio Vargas.

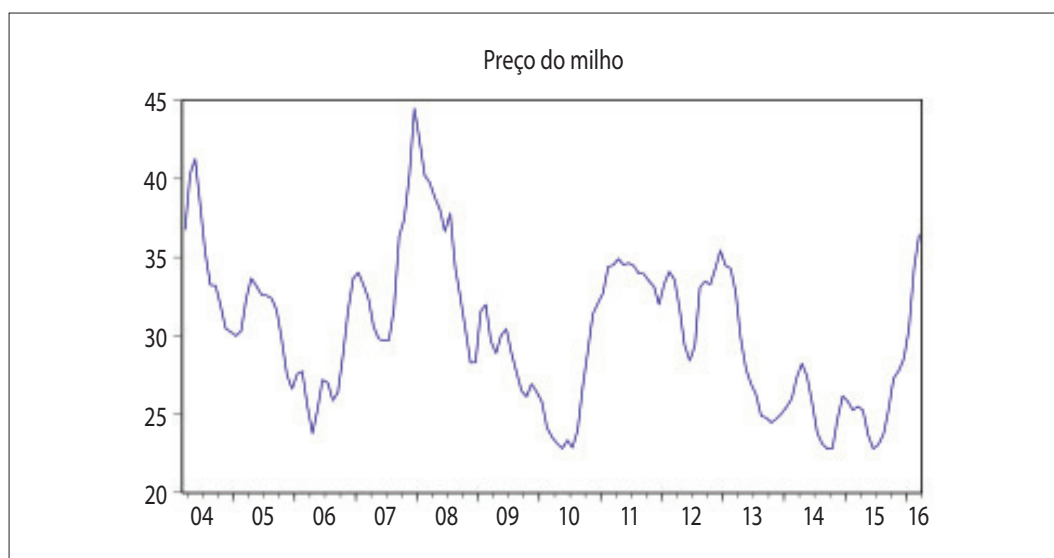
Os softwares utilizados foram Eviews 8.0 e Gretl.

4. RESULTADOS EMPÍRICOS E ANÁLISES

4.1. Análises gráficas e testes preliminares

As Figuras 1 e 2 mostram o comportamento das séries de cotações dos preços e retornos diários dos preços da *commodity* milho no período considerado.

Figura 1 - Preços médios mensais do milho (R\$/60Kg).



Fonte: Dados da pesquisa.

Figura 2 – Retornos médios mensais do milho.



Fonte: Dados da pesquisa.

Na inspeção visual da Figura 1, observa-se um comportamento com tendência crescente apresentando oscilações atingindo o seu pico de preço em dezembro de 2007. Dessa forma foi preciso testar a normalidade e estacionariedade da série mensais dos preços do milho para aplicação dos modelos ARIMA. Visualmente não permite afirmar que existe a presença da sazonalidade, fato este que será testado a partir do teste HEGY.

Algumas estatísticas descritivas básicas são apresentadas na Tabela 1. Observa-se que os preços médios do milho apresentam uma distribuição normal ao valor de curtose (2,6860). A estatística de Jarque-Bera indica p-valor de 0,0780, maior do que 5%, ou seja, não rejeita a normalidade da distribuição da série.

Tabela 1 – Sumário estatístico dos preços médios do milho.

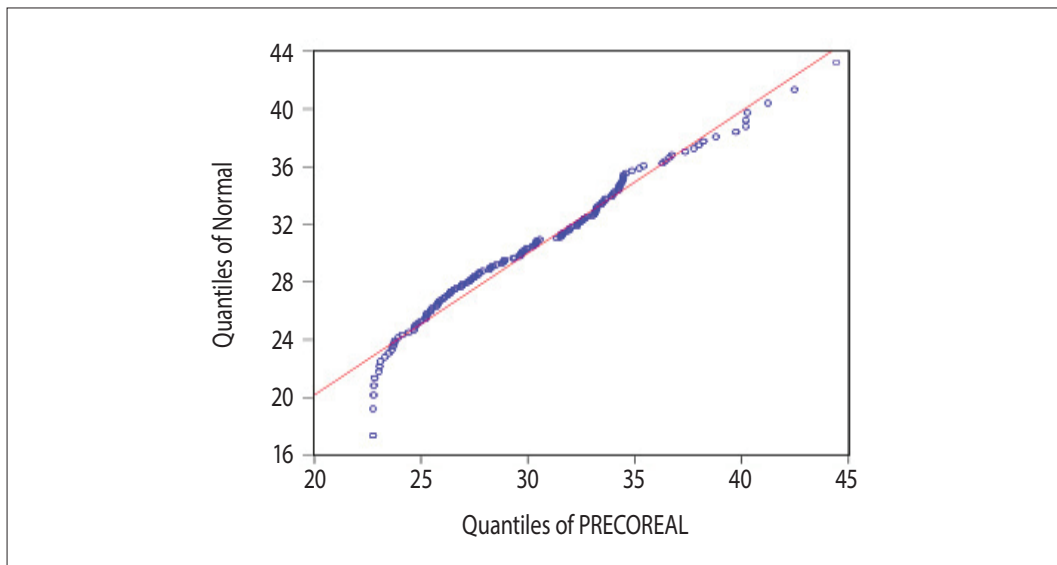
Estatísticas	Média	Mediana	Máximo	Mínimo	Desvio padrão
Valores	30,2435	29,9880	44,4712	22,7762	4,7845
Estatísticas	Assimetria	Curtose	Jarque-Bera	p-valor	Observações
Valores	0,4318	2,6860	5.1016	0,0780	145

Fonte: Elaboração do autor.

O Q-Q Plot representa um dos métodos gráficos mais utilizados na verificação da normalidade de séries temporais. O procedimento empregado consiste na comparação gráfica dos quantis teóricos da distribuição normal com os quantis dos dados amostrais.

A Figura 3 indica que a distribuição normal parece bem aderente aos dados. Assim sendo, todos os testes não rejeitaram a hipótese de normalidade da série analisada.

Figura 3 - Plot Q-Q Retornos médios mensais dos preços do milho.




Fonte: Dados da pesquisa.

4.2. Testes de raiz unitária e sazonalidade

Inicialmente, analisou as funções de autocorrelações (FAC) e de autocorrelações parciais (FACP). O comportamento dessas funções indica qual o modelo a ser utilizado. Ao realizar o estudo das funções em nível, de acordo com o correlograma, observa-se na Figura 4, um decaimento lento dos lag's o que indica de não estacionariedade, bem como a existência de sazonalidade, os quais serão verificados através dos testes de estacionariedade de ADF e KPSS e o teste de sazonalidade de HEGY.

Figura 4 - Função de autocorrelação e autocorrelação parcial do preço médio mensal do milho em nível.



Fonte: Dados da pesquisa.

Para investigar formalmente a não estacionariedade da série, foram utilizados os testes Dickey-Fuller Aumentado (ADF) e KPSS [Kwiatkowski, Phillips, Schmidt e Shin]. De acordo com a Tabela 2, as séries temporais de preços do milho em nível, foram estacionárias com constante e tendência, considerando o nível de significância de erro de 5%.

Tabela 2 – Testes de raiz unitária Dikey Fuller Aumentado (ADF) e Kwiatkowski, Phillips, Schmidt e Shin (KPSS).

Variável	ADF	Valor Crítico (5%)	KPSS	Valor Crítico (5%)	Decisão
Milho	-3,7146	-3,4415	0,0583	0,1460	Rejeita H_0

Fonte: Elaboração do autor.

O teste escolhido para verificar a sazonalidade das variáveis foi o teste de Hylleberg, Engle, Granger e Yoo (HEGY), por se tratar de séries temporais de preços agrícolas, sujeitos à existência de ciclos e tendências e à variação sazonal da produção. Os valores contidos na Tabela 3 mostram que, para a variável, em nível, se rejeita a hipótese de raiz unitária regular ($\pi_1 = 0$; H_0 : possui raiz unitária regular) com significância de 5%, logo a série é estacionária em nível. A hipótese de raiz unitária sazonal ($\pi_2 = 0$; H_0 : possui raiz unitária sazonal) foi rejeitada ao nível de significância de 5%. Portanto, a série não possui raiz unitária sazonal. Vale ressaltar que os resultados são semelhantes com os testes ADF e KPSS.

Tabela 3 - Teste HEGY para raiz unitária dos preços do milho com tendência e sazonalidade.

π	Teste HEGY	Valor crítico (5%)	Decisão
π_1	-4,1219	-2,820	Rejeita H_0
π_2	-2,2971	-1,940	Rejeita H_0

Fonte: Elaboração do autor.

Nota: Valores críticos de Franses e Hobijn (1997).

$t(\pi_1) = -3,40$ a 1%; $-2,82$ a 5%; $-2,52$ a 10% / $t(\pi_2) = -2,54$ a 1%; $-1,94$ a 5%; $-1,60$ a 10%

Com relação à sazonalidade, esta não foi identificada pelo teste HEGY. Assim, foram estimados modelos ARMA, conforme apresentados na tabela 7. No processo de modelagem e escolha dos modelos ARMA, devemos testar modelos diferentes e verificar a escolha do mais adequado com base nos menores valores dos critérios de informação Akaike (AIC), Schwarz (SIC), Theil, bem como a estatística de Durbin-Watson (DW) que também detecta a presença de autocorrelação nos resíduos de uma análise de regressão, ou seja, quando DW é aproximadamente igual a 2,0, ele indica que não existe autocorrelação nos resíduos. Desta forma, após várias simulações e com os critérios mencionados anteriormente, a melhor estimativa foi para o ARMA (1,2), devido aos menores valores observados para os critérios de AIC e SIC, coeficiente de Durbin-Watson (DW) e Theil. (Tabela 4).

Tabela 4 – Modelos estimados e critérios utilizados para seleção do melhor modelo.

Modelos	AIC	SIC	DW	Theil
AR (1)	3,7166	3,7373	0,950	0,0252
ARMA (1,1)	3,3493	3,3906	1,870	0,0208
ARMA (1,2)	3,3460	3,3079	2,040	0,0206

Fonte: Elaboração do autor.

A Equação estimada do modelo foi:

$$Y_t = 30,7744 + 0,8797 \varepsilon_{t-1} + 0,7424 \varepsilon_{t-1} + 0,1849 \varepsilon_{t-2} \quad (4)$$

p - valor (0,0000) (0,0000) (0,0000) (0,0000)

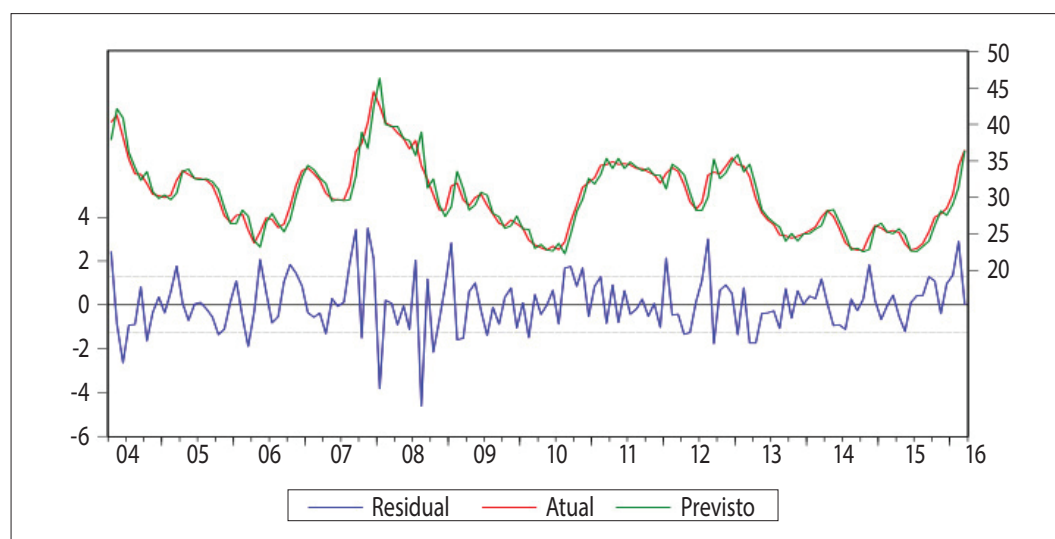
As estimativas dos preços médios do milho, no período de outubro de 2015 a março de 2016 são apresentadas na Tabela 5. No período de seis meses de estimativa a diferença entre os valores reais observados do milho e os valores estimados pelo modelo resultaram em uma diferença percentual aceitável em modelos de previsão diários de preços que apresentam uma volatilidade mais elevada. Na Figura 5, podem-se verificar os preços observados, os preços previstos e os valores residuais no período analisado. Portanto, as estimativas servem de embasamento para maior segurança em investimentos financeiros, dando suporte para produtores em suas tomadas de decisão.

Tabela 5 - Preços atuais e previstos mensais da *commodity* milho no período de outubro de 2015 a março de 2016.

Mês	Preço Atual	Preço Previsto	Erro (%)
Outubro/2015	27,29	26,56	- 2,67
Novembro	27,77	28,41	2,30
Dezembro	28,53	27,80	- 2,56
Janeiro/2016	30,42	29,23	- 3,91
Fevereiro	34,31	31,48	- 8,25
Março	36,46	36,21	- 0,68

Fonte: Elaboração do autor.

Figura 5 - Preços do milho observados, previstos e valores residuais no período de março de 2004 a março de 2016.



Fonte: Dados da pesquisa.


Após a escolha do modelo é necessário realizar a análise de resíduos (ajustado). Se o modelo for adequado aos dados espera aleatoriamente em torno de zero com variância aproximadamente constante. Também espera se que os resíduos sejam independentes e possuam distribuição normal. Na Figura 6 é apresentado o Teste Ljung-Box amostral é aproximadamente Qui-quadrado dos resíduos, cujas hipóteses podem ser interpretadas da seguinte maneira:

$$H_0 : \chi^2 = 0 \text{ (Resíduos independentes)}$$

$$H_1 : \chi^2 \neq 0 \text{ (Resíduos não são independentes)}$$

Pode-se observar que todas as observações possuem um p-valor alto, indicação de que os resíduos são independentes.

Figura 6 - Função de autocorrelação parcial e autocorrelação dos resíduos e teste Ljung-Box.



Fonte: Dados da pesquisa.

Uma forma de medir a capacidade preditiva do modelo consiste em comparar seus erros de previsão com aqueles do passeio aleatório. Isso pode ser feito através da chamada estatística U de Theil. O coeficiente U de Theil, avalia o desempenho da previsão em relação à previsão ingênua ou trivial. Previsão ingênua ou trivial significa que a estimativa do valor futuro é igual ao valor atual. O coeficiente U de Theil analisa a qualidade de uma previsão através dos seguintes valores:

- a) $U > 1$, significa que o erro do modelo é maior do que da previsão ingênua;
- b) $U < 1$, significa que o erro do modelo é menor que da previsão ingênua.

O coeficiente U de Theil menor do que 1 já indica uma previsão melhor que a previsão Ingênua; quanto mais próximo o mesmo for de zero, melhor será o resultado da previsão. A estatística U- Theil aplicada aos dados estimados e observados de março de 2004 a março de 2016 é 0,0206, indicando também uma boa qualidade do modelo em relação aos valores preditos.

5. CONCLUSÕES

A metodologia de previsão de Box-Jenkins é muito ampla, flexível e altamente subjetiva, mas, também é uma importante ferramenta de gestão que pode auxiliar o processo de tomada de decisão e planejamento futuro. Entretanto, o ponto fundamental para um mercado competitivo como o do milho é o de que uma antecipação de preços gera uma série de benefícios a todos os interessados neste agronegócio.

O modelo ARMA (1,2) estimado no presente estudo foi eficiente e apresentou projeção satisfatória para previsão dos preços do milho no mercado brasileiro. Os resultados obtidos fornecem uma ferramenta de análise para o mercado desta *commodity*, na medida em que demonstram a tendência dos preços para um horizonte de curto prazo, servindo de auxílio à tomada de decisão de agentes que comercializam este bem.

Apesar da modelagem ARMA apresentar um adequado poder de previsão de curto prazo, recomenda-se, em outros trabalhos de pesquisa, proceder à estimação utilizando outros modelos, tais como: ARMAX e volatilidade por meio da modelagem da família ARCH.

REFERÊNCIAS

- AGOLINK. Disponível em: <<http://www.agrolink.com.br/cotacoes/graos/soja>>. Acesso em: 17 de maio de 2016.
- AKAIKE, H. A. New look at the statistical model identification. *IEEE Transactions on Automatic Control*, Waschiton, v. 19, p. 716-723, 1973.
- ARÊDES, A. F.; PEREIRA, M. W. G. Potencialidade da utilização de modelos de séries temporais na previsão do preço do trigo no Estado do Paraná. *Revista de Economia Agrícola*, v. 55, n. 1, p. 63-76, 2008.
- BOX, G. P.; JENKINS, G. M. **Time series analysis, forecasting and control**. Holden-Day, San Francisco, 1976.
- DICKEY, D. A.; FULLER, W. A. Likelihood ratio statistics for autoregressive Time series with unit root. *Econometrica*, 49(4): 1057-1072, Julho, 1981.
- FELIPE, I. J. S. Aplicação de modelos Arima em séries de preços de soja no Norte do Paraná. *Tekhne e Logos*, v. 3, n. 3, 2012.
- FRANSES, P. H. **Testing for seasonal unit root in monthly data**. Econometric Institute Report, 9032A. Rotterdam: Erasmus University, 1990.
- FRANSES, P. H.; HOBIJN, B. Critical values for unit root tests in seasonal time series. *Journal of Applied Statistics*, v. 24, p. 25-46, 1997.
- HYLLEBERG, S.; ENGLE, R.; GRANGER, C.; YOO, B. Seasonal Integration and Cointegration. *Journal of Econometrics*, v. 44, p. 215-38, 1990.
- JARQUE, C.; BERA, A. Test for normality of observations and regression residuals. *International Statistical Review*, v. 55, n. 2, p. 163-172, 1987.
- LAMOUNIER, W. M. Tendência, ciclos e sazonalidade nos preços do café. *Gestão e Produção*, v. 14, n. 1, p. 13-23, 2007.
- LÜTKEPOHL, H.; KRÄTZIG, M. **Applied time series econometrics**. New York: Cambridge University Press, 2004. 323p.

MARQUES, D. V.; SOUZA, G.S.; SOUZA, M. O.; MARRA, R. Análise do mercado de café via modelos de previsão. In: SIMPÓSIO DE PESQUISA OPERACIONAL. 42. 2010. **Anais...** Bento Gonçalves, RS, 2010.

PHILLIPS, P. C. B.; PERRON, P. Testing for a unit root in time series regression. **Biometrika**, v. 75, n. 3, p. 335-346, 1988.

SOUZA, V. S.; NUNES, B. H. C.; ALMEIDA, A. N.; EISFELD, C. L. Utilização da metodologia de Box & Jenkins na previsão do preço futuro pago as exportações paranaenses de madeira serrada. In: ENCONTRO DE ECONOMIA PARANAENSE. 5, 2007. **Anais...** ECOPAR, UFPR, Paraná, PR, 2007.

ZIVOT, E.; W. K. ANDREWS. Further Evidence on the Great Crash, the Oil-Price Shock, and the Unit-Root Hypothesis. **Journal of Business and Economic Statistics**, v. 10, p. 251-270, 1992.