

O PREÇO DO FRANGO DE CORTE: EVOLUÇÃO E TENDÊNCIAS NO BRASIL *

Carlos Alberto Piacenti**

Jandir Ferrera de Lima***

Lucir Reinaldo Alves****

Moacir Piffer*****

Resumo: O objetivo deste artigo é analisar o acompanhamento e previsão dos preços futuros do frango de corte através do modelo ARIMA de previsão de séries temporais. Esse artigo fornece subsídios para produtores sobre as tendências de mercado e na minimização de situações de risco e incerteza no planejamento da produção. Com base nos resultados obtidos de previsão de preços a partir do modelo ARIMA(16,1,2) concluiu-se que o modelo apresentou um bom desempenho de predição. Isso resultou numa diferença média de 0,71%, nos seis meses analisados, percentual esse considerado satisfatório em modelos de previsão de preços.

Palavras-chave: Economia agrícola, preços futuros, séries temporais.

JEL: Q11, Q13, Q18

Abstract: The objective of this article is to analyze the accompaniment and forecast of the future prices of the chicken through ARIMA model of forecast of secular series. This article supplies to subsidies producers on the trends of market and in the risk and uncertainty situations in the planning of the production. On the basis of the gotten results of forecast of prices from the ARIMA (16,1,2) model concluded that the model presented a good performance of prediction. This resulted in an average difference of 0,71%, in the six analyzed months, percentile this considered satisfactory in models of forecast of prices.

Keywords: Agricultural economy, future prices, secular series.

JEL: Q11, Q13, Q18

* Uma versão preliminar desse artigo foi apresentada no Congresso da Sociedade Brasileira de Economia e Sociologia Rural (SOBER), na cidade de Fortaleza (CE), em agosto de 2006. Os autores agradecem as críticas e sugestões dos pareceristas.

** Doutorando em Economia Aplicada pela Universidade Federal de Viçosa (UFV). Professor assistente da Universidade Estadual do Oeste do Paraná (UNIOESTE)/Campus de Toledo. Pesquisador do Grupo de Estudos e Pesquisas em Agronegócio e Desenvolvimento Regional (GEPEC). E-mail: piacenti8@yahoo.com.br

*** Ph.D. em Desenvolvimento Regional pela Université du Québec (UQAC)-Canadá. Professor adjunto da UNIOESTE/Campus de Toledo. Pesquisador do CNPQ e do Grupo de Estudos e Pesquisas em Agronegócio e Desenvolvimento Regional (GEPEC). E-mail: jandir@unioeste.br, jandirbr@yahoo.ca

**** Mestre em Desenvolvimento Regional pela Universidade de Santa Cruz do Sul – UNISC. Professor assistente da UNIOESTE/Campus de Toledo. Pesquisador do Grupo de Estudos em Desenvolvimento Regional e Agronegócio (GEPEC). E-mail: lucir_a@hotmail.com

***** Doutorando em Desenvolvimento Regional pela Universidade de Santa Cruz do Sul – UNISC. Bolsista do governo brasileiro - CAPES. Professor assistente da UNIOESTE/Campus de Toledo. Pesquisador do Grupo de Estudos e Pesquisas em Agronegócio e Desenvolvimento Regional (GEPEC). E-mail: mopiffer@yahoo.com.br

Introdução

Atualmente, as discussões em torno dos subsídios agrícolas e políticas de proteção da agricultura nos países centrais têm chamado a atenção para a melhoria da produtividade e a criação de mecanismos que diminuam os riscos no setor. Até porque o comércio internacional não pode ser menosprezado no crescimento econômico e tem um papel de destaque no estímulo da produção. Assim, os países que tiverem custos relativamente menores para produzir determinado bem, deveriam dominar o mercado. Com isso, os produtores concentrariam seus insumos e sua estrutura produtiva na produção de mercadorias em que detiverem vantagens comparativas. No geral, todos os países ganhariam. Diferente de Ricardo (1986), para a corrente neoclássica do pensamento econômico, os custos da mão-de-obra representavam apenas uma parcela dos custos totais. Eles levam em consideração os custos dos recursos naturais, do capital e até mesmo da absorção de tecnologia. Essa corrente, que tem em Ohlin (1933) seu expoente, mantém a idéia das vantagens comparativas, mas incluem os efeitos do comércio internacional sobre a remuneração dos fatores de produção. O comércio internacional, supondo a total mobilidade dos fatores de produção, equalizaria a remuneração dos fatores de produção entre as nações.

Como contraponto à concepção de Ohlin (1933), Cardoso (1992) nos apresenta as idéias oriundas da Comissão Econômica para a América Latina e Caribe (CEPAL). Para a CEPAL as relações econômicas entre os países capitalistas centrais e os países capitalistas subdesenvolvidos tenderiam a acentuar a dependência dos últimos. Como os países desenvolvidos produzem tecnologia de ponta e se apropriam do progresso técnico, sua estrutura produtiva apresenta maiores vantagens comparativas, sem contar que o crescimento da produtividade é maior na produção de manufaturas em relação à produção agrícola. Por isso, a relação entre os bens produzidos nos países centrais e os produzidos na periferia é desigual. Como afirma Cardoso (1992: 35): “o preço dos produtos primários tende a declinar como proporção dos preços dos produtos industrializados...”

Da mesma forma que a produtividade dos bens manufaturados cresceu com a inserção dos avanços tecnológicos, o mesmo ocorreu na agricultura. Com a “revolução verde” ocorreu uma série de transferências tecnológicas para a produção agropecuária.

No Brasil, essa transferência foi estimulada pela política econômica dos governos na promoção das exportações e pela demanda dos mercados internacionais. De uma agricultura mista, voltada para o mercado local e internacional, o sistema intensivo marcou a transição para uma estrutura agrária cada vez mais internacionalizada, dependente do movimento dos mercados mundiais. De um produtor de gêneros agrícolas para o mercado

interno, a economia se especializou cada vez mais na produção de commodities. Assim, a viabilidade do aumento da produção ficou dependente do aumento dos rendimentos físicos e da oscilação dos preços no mercado internacional (BRAUN e FERRERA DE LIMA, 2005). Esse é o caso do frango de corte, ramo produtivo em que o Brasil vem ganhando espaço no mercado internacional (BRAUN, FERRERA DE LIMA e CARDOSO, 2007). Sob o ponto de vista do produtor agropecuário de frango de corte, esta necessidade está, em grande parte, relacionada com o comportamento dos preços que lhe serão pagos pela produção futura. Conforme salienta Barros (2003) na produção de qualquer bem, em especial no setor primário, a decisão sobre o uso dos insumos deve ser feita antes da produção. Por isso, o produtor precisa basear sua decisão não nos preços presentes, mas nos preços futuros. A tomada de decisão do produtor lhe faz entrar numa situação de risco e incerteza. Isso acentua a necessidade de se conhecer algumas variáveis que influenciam o comportamento dos preços, bem como seus coeficientes, para serem utilizados no planejamento e nas decisões de investimento futuro no setor.

Nesse sentido, o objetivo desse artigo é fornecer subsídios para o acompanhamento e previsão dos preços futuros através de modelos de séries temporais. Os modelos de séries temporais podem ser empregados para ajuste da série do preço do frango de corte e, conseqüentemente, para previsão de valores futuros. Esse estudo foi elaborado com o objetivo de testar a aplicabilidade de um modelo ARIMA de previsão de séries temporais, no caso, previsão do preço do frango de corte no Brasil. Esse artigo fornece subsídios para os pesquisadores analisarem as tendências de mercado, e, conseqüentemente, inferir sobre a minimização da situação de risco e incerteza em que os produtores se encontram através do uso do método ARIMA.

Aspectos teóricos e metodológicos

A metodologia utilizada neste trabalho fundamenta-se na construção de modelos univariados de previsão de preços com base em dados de séries temporais. Estes tipos de modelos diferem dos modelos estruturais aplicados à economia pelo fato de considerarem como essencial o comportamento das variáveis no tempo. Dessa forma, esses modelos não se preocupam com as variáveis explicativas, e sim com o estudo da evolução no tempo e da elaboração de uma função, na qual a variável dependente aparece em função dela mesma, regredida no tempo e/ou com os termos de erros, também defasados.

O modelo abordado é o Box-Jenkins univariado (UBJ). De acordo com Pankratz (1983), essa denominação é devido aos dois pesquisadores que mais contribuições fizeram a suas construções e aplicações: George E. P. Box e Gwilym M. Jenkins.

Este modelo também é denominado de Autoregressive Integrated Moving Average (ARIMA), ele baseia-se na idéia de que uma série temporal não-estacionária pode ser modelada a partir de “d” diferenciações e da inclusão de um componente auto-regressivo e um componente média móvel.

O modelo é expresso por: ARIMA (p, d, q), em que “p” representa a ordem da parte auto-regressiva, “q” a ordem da parte de média móvel e d o número de diferenciações realizadas para estacionarizá-la. Os modelos, quando não apresentam diferenciação em suas séries, podem ainda ser denominados como ARMA (p, q); quando só apresentam a parte auto-regressiva, como AR (p), ou quando apresentam apenas a parte de médias móveis, MA (q).

Outra importante maneira de expressão do modelo ARIMA é a utilização dos operadores de defasagem, geralmente através das letras B (backward shift operator) ou L (lag operator). O objetivo do operador é simplificar as expressões e colocar tudo expresso no tempo t.

A importância da estimação desses modelos reside na sua natureza extrapolativa ou de caráter “preditivo”. Sua vantagem no caso de previsões, em relação aos chamados modelos estruturais, é que nos modelos ARIMA as extrapolações não acumulam os erros de outras variáveis explicativas. Assim, quando se faz uma previsão com um modelo estrutural do tipo $Y = f(x, z)$, se estimam valores no futuro para “x” e “z” no intuito de prever o valor de “Y”, o que faz a previsão acumular os erros associados às variáveis “x” e “z”. No caso do modelo Box-Jenkins, do tipo: $Y = f(Y_{t-1}, Y_{t-2}, \dots, Y_{t-n}, e_{t-1}, e_{t-2}, \dots, e_{t-n}, e_t)$, não ocorre o já mencionado acúmulo dos erros.

Inúmeros trabalhos utilizando os modelos ARIMA são realizados nas mais diversas áreas de estudo da economia, principalmente com relação a determinação e previsão de preços para produtos industriais, commodities agrícolas, derivativos no mercado futuro, entre outras aplicações.

Aspectos teóricos dos modelos ARIMA

Os Modelos ARIMA (Auto-regressivo – Integrado – Média móvel), inicialmente formulados por Box e Jenkins (1976), baseiam-se na idéia de que uma série temporal não-estacionária pode ser modelada a partir de “d” diferenciações e da inclusão de um componente auto-regressivo e um componente média móvel.

A maioria das séries econômicas são não-estacionárias, no sentido de que a média e a variância não são constantes ao longo da amostra (GRANGER e NEWBOLD, 1986). No entanto, tais séries podem ser transformadas em séries estacionárias por diferenciação, ou seja, trabalhando com a diferença da série de t para t-1.

Séries não-estacionárias, em que as observações são descritas por tendências estocásticas, são conhecidas como séries não-estacionárias homogêneas (ABRAHAM e LEDOLTER, 1983). Tomando sucessivas diferença $\Delta y_t, \Delta^2 y_t, \dots$, a série não-estacionária homogênea y_t pode ser convertida em uma série estacionária z_t .

$$z_t = \Delta^d y_t = (1 - \beta)^d y_t \quad (1)$$

Sendo z_t um processo estacionário, ele é descrito através de uma modelagem ARMA (p, q), da seguinte forma:

$$\left| \Phi_p(\beta) z_t = \Theta_0 + \Theta_q(\beta) a_t \right. \quad (2)$$

que, ao se considerar a diferenciação (d) de y_t , corresponderá a um Modelo ARIMA(p, d, q), com

$$\left| \Theta_p(\beta)(1 - \beta)^d y_t = \Theta_0 + \Theta_q(\beta) a_t \right| \quad (3)$$

O primeiro termo de (3) é o operador auto-regressivo AR(p), ao passo que o segundo termo representa o operador média móvel MA(q), sendo até um processo ruído branco. Se Θ_0 for diferente de zero, a série integrada apresentará tendência determinística, ou seja, a série apresenta tendência crescente ou decrescente, que é independente dos distúrbios aleatórios (PINDYCK e RUBENFIELD, 1991).

De acordo com Box e Jenkins (1976) e Gujarati (2000), a modelagem ARIMA deve seguir três passos básicos antes de se proceder aos cálculos das previsões para a variável y_t :

- a) identificação/seleção do modelo;
- b) estimação; e
- c) verificação.

O passo mais importante é o primeiro, em que se determinam os valores apropriados de p, d e q . Nessa etapa, os usos do correlograma e do correlograma parcial auxiliam nessa tarefa.

Com relação à série diferenciada (e, portanto estacionária) z_t , pode-se reescrever a equação (2) como

$$a_t = \Theta_1 a_{t-1} + \dots + \Theta_q a_{t-q} + z_t - \Phi_1 z_{t-1} - \dots - \Phi_p z_{t-p} \quad (4)$$

dado o pressuposto de que a_t é independente e representado por uma distribuição normal com média zero e variância. A equação (4) descreve o modelo ARIMA (p,d,q) na sua forma generalizada, para construção de previsões de séries estacionárias.

O processo de estimação é complexo, porém com o auxílio dos pacotes estatísticos essa tarefa torna-se rotineira. Inicialmente, deve-se identificar os componentes do modelo, através de testes de raiz unitária e análise do correlograma, de modo a conduzir a estimação. Obtida a estimação, procede-se com a verificação do modelo. Esta é realizada analisando-se o comportamento dos resíduos. Especificamente, deve-se verificar se os resíduos \hat{a}_t seguem um processo tipo ruído branco, ou seja, com média próxima de zero, variância constante e correlações não significativas. Abraham e Ledolter, (1983). Nessa etapa de verificação procura-se ver se o modelo escolhido se ajusta aos dados razoavelmente bem, pois é possível que um outro modelo ARIMA possa desempenhar o mesmo papel. Segundo Gujarati (2000), daí por que a modelagem ARIMA de Box-Jenkins é mais uma arte do que uma ciência, é necessária habilidade para escolher o modelo correto.

Com a conclusão dos três passos básicos (identificação, estimação e verificação), é possível calcular previsões para os valores futuros de y_t . O modelo (4) é então, conforme Abraham e Ledolter (1983), representado em um formato equivalente, considerando a série original y_t :

$$|y_t = \pi_1 y_{t-1} + \pi_2 y_{t-2} + \dots + a_t| \quad (5)$$

sendo os pesos dados por

$$\frac{\phi(\beta)(1-\beta)^l}{1 - \pi_1\beta - \pi_2\beta^2 - \dots} = \frac{\phi(\beta)(1-\beta)^l}{\Theta_q(\beta)} \quad (6)$$

O objetivo dessa estimação consiste em prever y_{T+l} ($l > 1$) como resultado de uma combinação linear das observações y_T, y_{T-1}, \dots . Consideraram-se, então, previsões do tipo

$$y_T(l) = \eta_0 y_T + \eta_1 y_{T-1} + \eta_2 y_{T-2} + \dots \quad (7)$$

que são representadas por uma combinação linear dos distúrbios passados:

$$y_T(l) = \xi_0 a_T + \xi_1 a_{T-1} + \xi_2 a_{T-2} + \dots \quad (8)$$

A atualização da previsão é uma combinação linear da previsão anterior de y_{T+1}

feita no instante T com o erro de previsão um passo à frente mais recente, representado por

$$e(I) = y_{T+1} - y_T(I) = a_{T+1} \quad (9)$$

Segundo Pankratz (1983) e Granger e Newbold (1986), a metodologia Box- Jenkins deve ser aplicada em séries com mais de 50 observações, em casos onde as características estruturais são desconhecidas. Fischer (1982) ressalta outro importante aspecto dos modelos ARIMA, relacionado ao limite do horizonte de previsão. Segundo o autor, os ARIMA apresentam como característica geral de suas previsões reverterem a média quando o horizonte de previsão aumenta. Nesse sentido, o potencial de previsão destes modelos está limitado a horizontes de curto prazo.

Identificação dos modelos ARIMA

A seguir são mostrados alguns passos que devem ser seguidos quando da identificação do modelo, ou seja, da determinação das ordens de p (parte auto-regressiva), de d (quantidade de diferenciação) e q (parte dos termos de erros defasados – média móvel). Na prática utiliza-se um conceito de parcimônia que depende da sensibilidade do pesquisador, mas que invariavelmente não permite assumir valores de p, d e q maiores que 2. Evidentemente, em alguns casos, os valores podem ser mais elevados, principalmente de p e q. Assim, os passos a serem seguidos são:

a) Determinar se a série é estacionária: Utiliza-se o gráfico da função de autocorrelação (FAC) e de seu intervalo de confiança. Se a FAC apresenta um decréscimo acentuado nos seus primeiros valores, significa que a série é estacionária e $d=0$. Se o decréscimo for suave até atingir zero, significa que não é estacionária e terá o valor de d determinado pelo número de diferenciação. A cada diferenciação realiza-se e novo teste de estacionaridade. Se após algumas sucessivas diferenciações não se tornar estacionária, a série não será homogênea e os modelos ARIMA não serão aplicáveis. Caso a avaliação visual da FAC não seja conclusiva, pode-se proceder a testes específicos de raízes unitárias; um dos mais utilizados é o de Dickey-Fuller.

b) Determinar a ordem da parte auto-regressiva (valor de p) através do gráfico da função de autocorrelação parcial, FACP. O número de valores da FACP que estiverem acima do intervalo de confiança será considerado o valor máximo que p poderá atingir. É claro que deve-se sempre olhar o critério

de parcimônia. A FAC e FACP são facilmente obtidas por comandos dos softwares especializados em séries temporais, neste trabalho utilizou-se o EVIEWS.

c) Determinar a ordem da parte de média móvel (valor de q) através do gráfico da função de autocorrelação (FAC). Assim como na parte autorregressiva, o número de valores da FAC que estiverem acima do seu intervalo de confiança representa o valor máximo que q poderá atingir.

d) Estimar as combinações possíveis de modelos utilizando-se os máximos para p, d e q encontrados nas etapas anteriores. Desta forma, teremos um conjunto de modelos que devem ser escolhidos por alguns critérios estatísticos.

Após a estimação dos modelos prováveis, procede-se ao diagnóstico dos mesmos, através dos seguintes critérios:

Estadística t-Student: os valores de t em módulo de todos os coeficientes devem ser superiores a 2, ou seja, para 5% de significância.

Ruído branco: o modelo estatisticamente adequado, segundo Pankratz (1983), é aquele cujos erros são estatisticamente independentes, ou seja, não são autocorrelacionados. Se os erros forem serialmente correlacionados, existe uma relação na variável dependente yt que não está sendo considerada no modelo Box-Jenkins univariado (UBJ). O critério é o de que os valores de p-value da estatística Q (Box-Pierce e Ljung) com aproximação da distribuição qui-quadrada até pelo menos a 20 defasagem (Q 20) seja maior do que 0,05, ou seja, $P_i > 0,05$ ($i = 1, \dots, 20$).

Se após o diagnóstico descrito anteriormente, mais de um modelo for aprovado, deve-se proceder a uma previsão ex-post para cada modelo remanescente. O modelo que apresentar para essa previsão a menor soma dos desvios ao quadrado dos valores originais será o mais adequado.

O critério estatístico utilizado será o Erro Quadrado Médio de Previsão (EQMP), derivado do Erro Médio Percentual de Previsão, conforme definido em Armstrong e Fildes (1995) e por Bressan e Lima (2002). A estatística é definida como sendo:

$$EQMP_i = \frac{(VP_{t+1} - VO_{t+1})^2}{n} \quad (10)$$

A série estudada para análise é a série histórica de preços mensais do quilo do frango no Brasil, em reais observados no período de agosto 1994 a agosto de 2005. Para o ajuste do melhor modelo consideraram-se os meses de agosto de 1994 a fevereiro de 2005 e reservou-se o período de março a agosto de 2005 para ser usado como fonte de comparação dos dados da previsão para escolha do melhor modelo.

Os dados foram obtidos no site da FGVDADOS, na pasta: preços recebidos pelos produtores - Frango de Corte em Reais.

Análise e discussão dos resultados

Primeiramente, considera-se oportuno apresentar um gráfico da evolução dos preços do frango de corte no Brasil no período de agosto de 1994 a agosto de 2005.




Figura 1 - Evolução do preço nominal do frango de corte em reais, no período de ago/1994 a ago 2005

Fonte: FGVDADOS, 2005.

Essa série será utilizada para determinar a tendência no comportamento dos preços e determinar se a série é ou não estacionária. Visualmente, através da análise da Figura 1, percebe-se que esta série tende para cima, dando-nos a sensação de que ela não é estacionária

Analisando o gráfico de correlograma da saída do EVIEWS e através da função de autocorrelação (FAC) e de seu intervalo de confiança, pode-se através de seu comportamento ter uma sinalização sobre a estacionaridade ou não da série. Como nesse caso a FAC apresenta um decréscimo suave até atingir zero, significa que não é estacionária e terá o valor de d determinado pelo número de diferenciação. Outra forma de visualizar a não estacionaridade da série é através do intervalo de confiança, que neste caso foram calculadas para 36 observações, tem-se que acima da observação 32 os valores não são significativos, concluindo-se pela rejeição da hipótese de série estacionária.

O primeiro passo para o ajuste do modelo é a realização do teste de raiz unitária, o qual nos permitirá detectar ou não a presença de estacionaridade. Inicialmente, foram feitos os testes de raiz unitários em nível, com intercepto e também o teste em nível, com tendência e intercepto, conforme Tabela 1.

Tabela 1 – Teste de raiz unitária em nível, com tendência e intercepto.

Null Hypothesis: FRANGO has a unit root		
Exogenous: Constant, Linear Trend		
Lag Length: 1 (Automatic based on SIC, MAXLAG=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.154362	0.5105
Test critical values:		
	1% level	-4.029595
	5% level	-3.444487
	10% level	-3.147063

*MacKinnon (1996) one-sided p-values.

Fonte: Dados da pesquisa.

Dados os resultados da Tabela 1, do teste de raiz unitária em nível com tendência e intercepto sendo o valor de *t-Statistic* menor do que os valores críticos ao nível de 10% de significância, conclui-se pela não estacionaridade da série.

Realizando o teste de raiz unitária com uma diferença, com tendência e intercepto, conforme dados da Tabela 2, observa-se que fazendo a primeira diferença torna-se a série estacionária, ou seja, essa é a ordem que é preciso diferenciar a série para que ela se torne estacionária.

Tabela 2 – Teste de raiz unitária com uma diferença, com tendência e intercepto.

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-8.424910	0.0000
Test critical values:		
	1% level	-4.029595
	5% level	-3.444487
	10% level	-3.147063

Fonte: Dados da pesquisa.

Nota: *MacKinnon (1996) one-sided p-values.

Para determinar a ordem da parte autoregressiva (valor de p) utilizou-se o gráfico da função de autocorrelação parcial, FACP, inicialmente, selecionou-se o número de valores da FACP que estiveram acima do intervalo de confiança. Para determinar a ordem da parte de média móvel (valor de q), utilizou-se o gráfico da função de autocorrelação (FAC), assim como na

parte auto-regressiva, os números de valores da FAC que estiverem acima do seu intervalo de confiança representam o valor máximo que q poderá atingir. Conforme dados do Gráfico 1, de correlograma com uma diferença selecionou-se para rodar a primeira regressão um modelo com os componentes AR(1,4 e 12) e os componentes MA (1,4,5,8 e 9), conforme Tabela 3.

Os resultados obtidos com o modelo ARIMA(12,1,9), apresentam alguns resultados não significativos para as variáveis AR(1), AR(12) e MA(9).

Tabela 3 – Regressão ARIMA (12,1,9), utilizando a variável dependente D(PFRANGO)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.009861	0.006059	1.627524	0.1066
AR(1)	-0.137401	0.180616	-0.760737	0.4485
AR(4)	0.600729	0.265405	2.263445	0.0257
AR(12)	0.084239	0.147479	0.571196	0.5691
MA(1)	0.373948	0.189640	1.971887	0.0513
MA(4)	-0.854508	0.283389	-3.015318	0.0032
MA(5)	-0.257665	0.144728	-1.780338	0.0779
MA(8)	0.342390	0.148418	2.306940	0.0230
MA(9)	0.120587	0.117877	1.022989	0.3087
R-squared	0.208616		Mean dependent var	0.009035
Adjusted R-squared	0.148320		S.D. dependent var	0.043150
S.E. of regression	0.039821		Akaike info criterion	-3.533173
Sum squared resid	0.166502		Schwarz criterion	-3.317157
Log likelihood	210.3908		F-statistic	3.459872
Durbin-Watson stat	1.868949		Prob(F-statistic)	0.001410

Fonte: Dados da pesquisa.

Realizando o teste de Breusch-Godfrey, que é uma alternativa ao teste Q de Ljung-Box e pertence aos testes assintóticos conhecidos como testes do multiplicador de Lagrange. Esse teste contempla a possibilidade de erros do tipo ARMA(p,q) e é aplicado caso haja ou não termos defasados do lado direito da equação. Conforme resultados da Tabela 4, observa-se que o valor da probabilidade de Obs*R-squared é maior que 10%, indicando que se deve aceitar hipótese nula (H0), ou seja, de que todos os coeficientes auto-regressivos são simultaneamente iguais a zero, indicando que não existe a presença de autocorrelação nos resíduos.

Tabela 4 - Teste de Breusch-Godfrey para o modelo ARIMA(12,1,9)

Breusch-Godfrey Serial Correlation LM Test:			
F-statistic	2.144266	Probability	0.122355
Obs*R-squared	4.549604	Probability	0.102817

Fonte: Dados da pesquisa.

A análise de estacionaridade dos resíduos para o modelo ARIMA(12,1,9), são apresentados na Tabela 5, conforme o valor obtido do teste de Dickey-Fuller aumentado, conclui-se pela estacionaridade dos resíduos, dado ser o valor da estatística de Dickey-Fuller maior do que os valores críticos.

Tabela 5 - Teste de raiz unitária dos resíduos para o modelo ARIMA(12,1,9)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-9.920075	0.0000
Test critical values:		
1% level	-2.585587	
5% level	-1.943688	
10% level	-1.614850	

Fonte: Dados da pesquisa

Nota: *MacKinnon (1996) one-sided p-values.

Conforme foi descrito na metodologia, é necessário estimar diversas combinações possíveis de modelos de forma que teremos um conjunto de modelos que deverão ser escolhidos de acordo com os critérios estatísticos apresentado, ou seja, Erro Quadrado Médio de Previsão (EQMP). Para este trabalho foram estimados 14 modelos como os mais prováveis, e cujos resultados dos EQMP são apresentados na Tabela 6.

Tabela 6 – Modelos estimados e resultados dos EQMP.

Ordem	MODELO	EQMP
1	AR(1,4,12); MA(1,4,5,8,9)	0,0205
2	AR(4,12); MA(1)	0,0051
3	AR(1,4,12)	0,0047
4	AR(4,8,12); MA(1)	0,0040
5	AR(4,8,12); MA(1,2)	0,0030
6	AR(1,4,8,12); MA(1,2)	0,0024
7	AR(1); MA(1)	0,0023
8	AR(1,4,8,12,16)	0,00053
9	AR(1,4,8,12,16); MA(1,2)	0,00030
10	AR(4,8,12,16); MA(1,2)	0,00028
11	AR(1,4,8,12); MA(1)	0,00074
12	AR(4,8,12); MA(1)	0,0011
13	AR(4,8,12,16,20); MA(1,2)	0,0004
14	AR(4,8,12,16,20); MA(1)	0,0011

Fonte: Dados da pesquisa.

Conforme dados da Tabela 6 o modelo que apresentou o menor EQMP, foi o modelo 10, ou seja, o modelo ARIMA(16,1,2), e utilizando-se do conceito de parcimônia em que invariavelmente não permite-se assumir valores de p, d e q maiores que 2, onde porém, em alguns casos os valores podem ser mais elevados, principalmente de p e q, estimou-se também modelos ARIMA(1,1,1), ARIMA(2,1,1) entre outros, porém, devido a esses apresentarem EQMP maiores do que o modelo ARIMA(16,1,2), optou-se para efeito de apresentação dos resultados, apenas os dados do modelo de menor EQMP.

Tabela 7 - Modelo 10 – ARIMA(16,1,2), utilizando a variável dependente D(PFRANGO)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.010981	0.008109	1.354093	0.1787
AR(4)	-0.253036	0.097648	-2.591309	0.0109
AR(8)	0.117470	0.095891	1.225033	0.2234
AR(12)	0.320297	0.094808	3.378382	0.0010
AR(16)	0.139659	0.098192	1.422298	0.1580
MA(1)	0.297206	0.098731	3.010273	0.0033
MA(2)	0.147447	0.099782	1.477684	0.1425
R-squared	0.204057	Mean dependent var		0.009636
Adjusted R-squared	0.157692	S.D. dependent var		0.043281
S.E. of regression	0.039722	Akaike info criterion		-3.552285
Sum squared resid	0.162520	Schwarz criterion		-3.380436
Log likelihood	202.3757	F-statistic		4.401046
Durbin-Watson stat	1.995522	Prob(F-statistic)		0.000533

Fonte: Dados da pesquisa.

Os resultados obtidos com o modelo 10 e que estão representados através da Tabela 7, apresentam três variáveis não significativas ao nível de 10%, porém, quando se estima um novo modelo, excluindo-se essas variáveis, ou seja, o modelo 2, tem-se que o valor do EQMP é maior, dado que nesses modelos de previsão, o mais importante é a proximidade do valor previsto com o valor observado, do que a significância do parâmetro estimado.

Tabela 8 -Teste de Breusch-Godfrey para o modelo ARIMA(16,1,2)

Breusch-Godfrey Serial Correlation LM Test:			
F-statistic	0.024070	Probability	0.976223
Obs*R-squared	0.052403	Probability	0.974139

Fonte: Dados da pesquisa.

Realizando o teste de Breusch-Godfrey, conforme resultados da Tabela 8, observa-se que o valor da probabilidade de Obs*R-squared é maior que 10%, indicando nesse caso que se deve aceitar hipótese nula (H0), ou seja, não existe a presença de autocorrelação nos resíduos.

A análise de estacionaridade dos resíduos para o modelo ARIMA(16,1,2), são apresentados na Tabela 9, conforme o valor obtido do teste de Dickey-Fuller aumentado, conclui-se pela estacionaridade dos resíduos, por ser o valor da estatística de Dickey-Fuller maior do que os valores críticos.

Tabela 9 - Teste de raiz unitária dos resíduos para o modelo ARIMA(16,1,2)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		-10.36912	0.0000
Test critical values:	1% level	-2.586350	
	5% level	-1.943796	
	10% level	-1.614784	

Fonte: Dados da pesquisa.

Nota: *MacKinnon (1996) one-sided p-values.

Para obter os valores dos preços estimados, relativos ao período de março a agosto de 2005 para o modelo selecionado, utilizou-se a ferramenta Forecast do Eviews 4.1. Os dados da Tabela 10 apresentam os preços observados e os preços estimados, bem como a diferença percentual entre eles.

Tabela 10 - Resultado da previsão de preço de frango, utilizando o modelo ARIMA(16,1,2), e a diferença percentual entre o preço real e o estimado, no período de março a agosto de 2005.

Período	Preço observado	Preço estimado	%
mar/05	1,83	1,82	-0,419
abr/05	1,82	1,83	0,731
mai/05	1,83	1,84	0,780
jun/05	1,84	1,86	0,828
jul/05	1,84	1,87	1,425
ago/05	1,86	1,88	0,925
Média	-	-	0,712

Fonte: Dados da pesquisa.

Dado o modelo utilizado, os valores obtidos na previsão são muito próximos aos valores observados. No intervalo de seis meses de estimativa a diferença na previsão em cinco deles fica abaixo de 1%, e em apenas um mês o erro da estimativa ultrapassou a 1,4%. O bom desempenho de previsão do modelo resultou numa diferença média de 0,71%, percentual esse considerado satisfatório em modelos de previsão de preços.

Conclusão

Os modelos de séries temporais no domínio do tempo podem ser empregados para ajuste da série do preço do frango de corte e, conseqüentemente, para previsão de valores futuros.

O presente trabalho foi elaborado com o objetivo de testar a aplicabilidade de um modelo de previsão de séries temporais, no caso, previsão do preço do frango de corte no Brasil e o modelo especificamente estudado foi o ARIMA.

Os resultados são analisados a partir do desempenho “preditivo”, para tanto foram estimados 14 modelos ARIMA, e a escolha do melhor modelo se deu com base no menor EQMP de cada um dos modelos.

Com base nos resultados obtidos de previsão de preços a partir do modelo ARIMA(16,1,2), pode-se concluir que o modelo apresentou um bom desempenho “preditivo”, o que resultou numa diferença média de 0,71%, nos seis meses analisados, sendo esse percentual considerado satisfatório em modelos de previsão de preços.

Os resultados desse modelo ARIMA(16,1,2), embora diferencie do conceito da parcimônia em que invariavelmente não se permite assumir valores de p, d e q maiores que 2. Porém, em alguns casos os valores podem ser mais elevados, principalmente de p e q, que são considerados aceitáveis, pois a natureza da atividade é planejamento a médio e longo prazo.

Portanto, é importante salientar que, ao trabalhar com séries econômicas, as previsões a longo-prazo podem diferir dos valores reais, devido a fatos não previstos que possam ocorrer no período. No caso do produtor de frango, é necessário ter sempre em mente a possibilidade de ocorrência de fatos não esperados que possam afetar o preço do seu produto, tais como: a desvalorização do Real frente ao Dólar e o uso de barreiras tarifárias e não-tarifárias pelos países importadores, medidas essas que acabam afetando o preço do frango.

Referências

ABRAHAM, B.; LEDOLTER, J. **Statistical methods for forecasting**. New York: John Wiley & Sons, 1983.

ARMSTRONG, J. S; FILDES, R. **On the selection of error measures for comparsion among forecasting methods**. *Journal of Forecasting*, v. 14, p. 67-71, 1995.

BARROS, G. S. C. Economia da Comercialização Agrícola. Piracicaba, Capítulo 7, p. 7, 2003. Disponível em <www.cepea.esalq.usp.br>, Acesso em: 20 dez. 2005.

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

BRAUN, M. B. S.: FERRERA DE LIMA, J. **Política comercial e a exportação de produtos agrícolas brasileiros**. Revista REDES. Santa Cruz do Sul, v. 10, nº 02, p.37-54, 2005.

BRAUN, M. B. S.; FERRERA DE LIMA, J.; CARDOSO, R. **Inserção mundial e competitividade da agricultura brasileira**. Revista GEPEC. Toledo, v. 11, n° 01, p.33-50, 2007.

BRESSAN, A. A.; LIMA, J. E. de. **Modelos de previsão de preços aplicados aos contratos futuros de boi gordo na BM&F**. Revista Nova Economia, Belo Horizonte, v.12 n° 1, 2002.

CARDOSO, F. H. **As idéias e o seu lugar: Ensaio sobre as teorias do desenvolvimento**. Petrópolis (RJ): Vozes, 1992.

FISCHER, S. **Séries univariantes de tempo: metodologia de Box & Jenkins**. Porto Alegre, FEE, 1982. 186 p. Dissertação (Mestrado em Economia) – Universidade Federal do Rio Grande do Sul, 1982.

FUNDAÇÃO GETÚLIO VARGAS. **Site Institucional**. Disponível em: http://www.fgvdados.fgv.br/dsp_series.aspFGVDADOS. Acesso em 12 dez. 2005.

GRANGER, C. W. J.; NEWBOLD, P. **Forecasting Economic Time Series**. London, Academic Press, 1986.

GUJARATI, D. N. **Econometria básica São Paulo: Pearson Education do Brasil**, 2000.

OHLIN, B. **Interregional and international trade**. Cambridge: Harvard University Press, 1933.

PANKRATZ, A. **Forecasting With Univariate Box-Jenkins Models**. New York: John Wiley & SONS, 1983.

PINDYCK, R. S.; RUBENFIELD, D. L. **Econometric models and economic forecasts**. 3 ed. New York: McGrawHill, 1991.

RICARDO, D. **Princípios de economia política e tributação**. (Coleção os economistas). São Paulo: Nova Cultural, 1986.

Artigo recebido em 11.10.2007 e aceita a versão final em 13.08.2008