

## PREVISÃO DE PREÇOS DO BOI GORDO COM MODELOS ARIMA E SARIMA<sup>1</sup>

Saulo Jardim de Araujo<sup>2</sup>

Alan Figueiredo de Aredes<sup>3</sup>

Vladimir Faria dos Santos<sup>4</sup>

**Resumo:** O artigo teve como objetivo avaliar a eficácia dos modelos de séries temporais ARIMA (Auto-Regressivo Integrado de Médias Móveis) e SARIMA (Modelo Sazonal Auto-Regressivo Integrado de Médias Móveis) na previsão de preços do boi gordo em Campos dos Goytacazes-RJ. Para isso, foi usada a metodologia de *Box-Jenkins* para a modelagem da série de preços do boi gordo na localidade, sendo o poder de previsão dos modelos medido pelo indicador Erro Quadrado Médio de Previsão (EQMP). De acordo com os resultados, conclui-se que os modelos são instrumentos eficazes na previsão dos preços do boi, especialmente o modelo SARIMA que apresentou o menor EQMP.

**Palavras-chaves:** Preço, séries, previsão.

**Abstract:** The paper aimed to assess the effectiveness of time series models ARIMA (Autoregressive Integrated Moving Averages) and SARIMA (Model Seasonal Autoregressive Integrated Moving Averages) in predicting live cattle prices in Campos dos Goytacazes-RJ. For this, we used the Box-Jenkins methodology for modeling the number of live cattle prices in the locality, and the predictive power of the models measured by the Mean Square Error of Prediction (EQMP). According to the results, it is concluded that the models are effective tools in forecasting the price of cattle, especially the SARIMA model that had the lowest EQMP.

**Keywords:** Price, series, prediction.

### 1. INTRODUÇÃO

A análise dos preços agrícolas é de crucial importância para a empresa rural. Ela permite que o empresário avalie com mais precisão o retorno da atividade agrícola e o risco de perdas financeiras ocasionadas por oscilações desfavoráveis dos preços dos produtos e dos fatores de produção. Permite que o produtor rural aloque melhor seus

<sup>1</sup> Pesquisa realizada com Auxílio à Pesquisa – APQ1, FAPERJ.

<sup>2</sup> Graduando em Ciências Econômicas. Departamento de Ciências Econômicas. Universidade Federal Fluminense (UFF). E-mail: saulojardim@id.uff.br.

<sup>3</sup> Doutor em Economia Aplicada. Departamento de Ciências Econômicas. Universidade Federal Fluminense (UFF). E-mail: aredess@yahoo.com.br.

<sup>4</sup> Doutor em Economia Aplicada. Departamento de Ciências Econômicas. Departamento de Ciências Econômicas. Universidade Federal Fluminense (UFF). E-mail: vladi\_fs@yahoo.com.br.

recursos, elevando as margens de retorno do capital investido e diminui os riscos da atividade.

A previsão de preços é um instrumento de grande relevância na tomada de decisão, especialmente no que se refere ao agronegócio, que é caracterizado pela exposição a distúrbios irregulares. Nesse sentido, serve como ferramenta no planejamento, avaliação de políticas e minimização dos riscos na tomada de decisão dos produtores, compradores e investidores (BRESSAN e LIMA, 2005).

Assim, o monitoramento dos preços e suas projeções oferecem ao administrador elementos indispensáveis ao negócio agrícola. Segundo Vale *et al.* (2002) a seleção de preços a serem utilizados no processo de análise é um dos passos básicos do planejamento, sendo necessário um estudo de preços com critério para estabelecer o preço que será utilizado na análise.

Segundo Vale *et al.* (2002), entre as características mais desejáveis de um planejamento constam-se as perspectivas de preços. De acordo com os autores, o planejamento é definido como o ato de organizar recursos como terra, trabalho, capital e administração para que os objetivos da empresa sejam atingidos. Para Woiler e Mathias (1986) o planejamento pode ser entendido como um processo de tomada de decisões interdepende que procuram levar a empresa para uma situação futura.

Diante da importância dos preços no planejamento e na tomada de decisão, o artigo tem como objetivo avaliar a eficácia dos modelos de série temporais ARIMA (Auto-Regressivo Integrado de Médias Móveis) e SARIMA (Modelo Sazonal Auto-Regressivo Integrado de Médias Móveis) na previsão de preços do boi gordo em Campos dos Goytacazes-RJ. Espera-se que os modelos sejam eficazes e que possam ser empregados como critérios no planejamento e tomada de decisão dos pecuaristas, aumentando os rendimentos e reduzindo os riscos de variação dos preços na atividade.

O mercado da carne do boi foi escolhido para o estudo devido a importância econômica do setor para o país e, em especial, para a região de Campos dos Goytacazes. Como apontam Ponciano *et al.* (2004), na região Norte Fluminense se destacam como principais atividades a produção de cana-de-açúcar, pecuária bovina e café. Quase 70% dos estabelecimentos possuem como atividades principais a produção de cana-de-açúcar e bovinos.

## 2. MATERIAIS E MÉTODOS

### 2.1. Formação de preços e riscos na bovinocultura de corte

Pode-se dizer que o preço da carne bovina é determinado por diversos fatores, que vão desde os relacionados à produção – como o clima e preço dos insumos – até os relacionados à fase de consumo, como o preço de produtos concorrentes e variáveis macroeconômicas (inflação, taxa de juros, câmbio e PIB) que afetam a demanda do produto.

Como aponta Arêdes (2009), considerando que a carne suína, bovina e de frango são substitutas, espera-se que seus preços estejam relacionados e que uma mudança no preço de uma dessas carnes seja transmitida as demais. Dessa forma, por exemplo, uma alta no preço da carne de frango deve ocasionar a maior procura de carne suína e bovina por parte do consumidor, promovendo, a elevação dos preços desses dois tipos de carne.

Estudo realizado pelo autor mostra que os preços da carne bovina e de frango causam no sentido de Granger o preço da carne suína; o preço da carne suína causa o preço da carne bovina; e o preço da carne bovina causa o preço da carne de frango. Assim, ressaltando a interdependência entre os preços desses produtos. Medeiros e Montevechi (2005) também apontam que os produtos substitutos podem afetar muito o preço do boi. Segundo eles, IEL, CNA e SEBRAE (2000) apontam que o frango é o principal substituto da carne bovina e, que dessa forma, mudanças em seus preços podem afetar o consumo e o preço da carne bovina.

No que diz respeito ao clima e ao processo produtivo, segundo Medeiros e Montevechi (2005), existem ainda três fases para a finalização da produção da carne bovina, a saber: cria, recria e engorda. O Quadro 1 demonstra as três fases, e nele pode-se verificar que as duas principais variáveis para a produção de carne bovina na maioria das propriedades são a qualidade dos pastos - que é variável dependente do clima - e a eficiência produtiva, que está diretamente ligada a velocidade de crescimento do animal e que, por fim, é o principal determinador das variações nos preços do produto (MEDEIROS; MONTEVECHI, 2005).

QUADRO 1 – Características e fases da pecuária bovina no Brasil.

Fases	Cria	Recria	Engorda
Características			
Categoria animal ao final da fase	Bezerro	Boi Magro	Boi Gordo
Idade média	até 8 meses	de 8 a 36 meses	até 48 meses
Duração da fase	de 6 a 8 meses	de 6 a 24 meses	de 6 a 18 meses
Peso ao final da fase	de 4 a 8 arrobas	de 13 a 15 arrobas	mais de 16,5 arrobas
Sistema de criação	Extensivo à pasto	Extensivo e Semi-extensivo à pasto	Semi-intensivo à pasto e Intensivo com confinamento
Nível tecnológico	Baixo e pouco desenvolvido	Médio/Alto e Desenvolvido	Alto e Muito desenvolvido
Localização dos criatórios	Áreas distantes dos centros consumidores e em terras com baixa fertilidade	Áreas mais próximas a centros consumidores e em terras com média/alta fertilidade	Áreas próximas a centros consumidores e em terras com alta fertilidade

Fonte: Medeiros e Montevechi (2005), criada a partir de dados Schouchana e Caffagni (2001), IEL, CNA e SEBRAE (2000).

De acordo com Igreja (1987), citado por Medeiros e Montevechi (2005), a formação de preços da bovinocultura de corte está relacionado às variações sazonais (Figura 1) e ao ciclo plurianual, que pode ser entendido analisando a Figura 2.

Conforme Medeiros e Montevechi (2005), no período das águas observa-se uma maior quantidade de forrageira disponível para o gado, com isso aumenta-se a criação de animais, o que causa uma queda no preço do bovino, devido à expansão da oferta. Em contra partida, no período de seca ocorre o contrário, como pode-se observar na Figura 1.



Fonte: Medeiros e Montevechi (2005), criada a partir de dados de Kassouf (1988), IEL, CNA e SEBRAE (2000).

Nesse sentido, nota-se que são muitas as variáveis que podem afetar o nível de preço da carne bovina, sendo estas fontes de risco à atividade pecuária, uma vez que as receitas obtidas pelos bovinocultores são formadas a partir dos preços recebidos pelo produto. Assim, quanto menor o nível de preço recebido pelo pecuarista menor sua margem de lucro e menor a capitalização do setor. O que revela a importância do planejamento da produção e do monitoramento dos preços para o bom desempenho da atividade.

## 2.2. Modelo ARIMA e SARIMA

O modelo ARMA (Auto-Regressivo e de Média Móvel) de Box e Jenkins (1976) é dado pela estimação da regressão da variável dependente  $Y$  em função das defasagens da própria variável  $Y$ , indicado por  $p$  termos auto-regressivos, e em função dos erros aleatórios, indicado por  $q$  termos média móvel, sendo o modelo indicado como ARMA.

Assim, o modelo ARMA (1,1) pode ser escrito como:

$$Y_t = \theta + \alpha_1 Y_{t-1} + \beta_0 u_t + \beta_1 u_{t-1}$$

em que  $Y$  é a série temporal;  $u$  é o termo de erro aleatório; e  $\theta$ ,  $\alpha$  e  $\beta$  são os parâmetros a serem estimados (GUJARATI, 2000).

Porém, como a maioria das séries temporais econômicas é naturalmente não-estacionárias, a aplicação do modelo exige a transformação das mesmas por  $d$  diferenças para torná-las estacionárias. O modelo assim obtido é denominado ARIMA (Auto-Regressivo Integrado de Média Móvel), sendo apresentado como ARIMA (p,d,q).

Assim, para uma série não estacionária em nível e um modelo com  $p$  termos auto-regressivos e  $q$  termos média móvel, temos o modelo ARIMA (p,d,q), escrito como:

$$\Delta Y_t = \theta + \alpha_1 Y_{t-1} + \alpha_p Y_{t-p} + \beta_0 u_t + \beta_1 u_{t-1} + \beta_q u_{t-q}$$

em que  $\Delta$  é o operador de diferenças.

Porém, muitas séries de preços apresentam um componente sazonal e pode ser necessário modelar esse a fim de obter um modelo mais confiável. Assim, foram desenvolvidos os modelos SARIMA (Modelo Sazonal Auto-Regressivo Integrado de Médias Móveis), que são os modelos ARIMA sazonais (PACHECO, 2001). Conforme o autor, tal modelo é apresentado como SARIMA  $(p,d,q)(P,D,Q)_s$ , em que  $s$  é o período correspondente a sazonalidade. Em termos de equação, tem-se:

$$\Phi(B^s)\phi(B)(1-B)^d(1-B^s)^D X_t = \Theta(B^s)\theta(B)Z_t,$$

em que  $\Phi(B^s)$  são os coeficientes sazonais de autorregressão;  $\Theta(B^s)$  são os coeficientes sazonais das médias móveis; e  $(1-B^s)^D$  é o operador de diferença de ordem  $D$  de diferenciação sazonal (PACHECO, 2001).

### 2.3. A metodologia de Box-Jenkins

Conforme Gujarati (2000), a metodologia de *Box-Jenkins* para modelagem de um processo ARIMA consiste em quatro etapas:

- a) Identificação: a primeira etapa consiste em obter os valores apropriados para  $p$ ,  $d$  e  $q$ . Para isso, pode-se empregar o correlograma e o correlograma parcial, que são as representações gráficas da Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACP) contra o tamanho da defasagem;
- b) Estimativa: estimam-se os parâmetros do modelo, o que pode ser feito por meio de mínimos quadrados ou pelo método de estimativa não-linear;
- c) Checagem de diagnóstico: é verificado se o modelo estimado ajusta-se bem aos dados. Uma maneira de fazer esta checagem é ver se os resíduos do modelo são ruídos brancos. Caso sejam, aceita-se o modelo. Caso contrário, o processo deve ser recomeçado a fim de se identificar outro modelo; e
- d) Previsão: o modelo é usado para fazer previsões.

## 2.4. Teste de raiz unitária

Antes de realizar o teste de causalidade e estimar as equações de transmissão de preços é necessário verificar se as séries de dados são estacionárias. Caso estas não sejam estacionárias, elas devem ser diferenciadas até se tornarem estacionárias.

Para essa verificação pode-se empregar a análise gráfica e a Função de Autocorrelação (FAC). Porém, um teste mais específico é o teste de raiz unitária de Dickey-Fuller Aumentado (ADF). Conforme Gurajati (2000), a equação de teste de raiz unitária ADF é representada como:

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

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;  $\delta$ , o parâmetro da variável defasada  $Y_{t-1}$ ;  $\alpha_i \sum_{i=1}^m \Delta Y_{t-i}$ , o termo de diferenças defasadas; e  $\varepsilon_t$ , o erro aleatório.

A não estacionariedade da variável é constatada pela existência de raiz unitária na série de dados. Para isso, deve-se estimar a equação acima e testar a significância estatística do parâmetro  $\delta$ , com as seguintes hipóteses:

$$H_0 : \delta = 0$$

$$H_1 : \delta \neq 0$$

Caso a hipótese nula testada não for rejeitada, a série possui raiz unitária. Confirmada a presença de raiz unitária na série esta deve ser diferenciada e testada novamente para a presença de raiz em diferenças, sendo realizadas  $d$  diferenciações até que o teste de raiz unitária seja rejeitado.

## 2.5. Critério de avaliação de previsão

Para avaliar a eficácia dos modelos de previsão, pode-se usar o método estatístico Erro Quadrado Médio de Previsão (EQMP). Conforme Morettin e Tolo (2004), o EQMP pode ser usado para comparar a eficácia entre modelos de previsão, quando se quer o modelo com melhores previsões. O método é dado por:

$$EQMP = \left[ \sum_{h=1}^n (VO_{t+h} - VP_{t+h})^2 \right] / n$$

em que  $h=1,2,3,\dots,n$ ; que corresponde as previsões para os últimos  $n$  dias.

## 2.6. Fonte de dados

Os dados utilizados são referentes à série de preços mensal da arroba do boi na região de Campos dos Goytacazes-RJ, no período de 01/2005 a 12/2009. A série foi obtida junto ao ANUALPEC (2010). As modelagens foram feitas de janeiro de 2005 a dezembro de 2008 e as previsões foram realizadas para o período de janeiro a dezembro de 2009. A pesquisa foi feita para esse período devido a disponibilidade de dados.

## 3. RESULTADOS E DISCUSSÃO

Conforme Gujarati (2000), o primeiro passo para analisar toda uma série temporal é fazer a representação gráfica dos dados. Nesse sentido, foi plotada em um gráfico (Figura 3) a série de preços do boi gordo em Campos dos Goytacazes – RJ. Pela análise gráfica, os preços apresentaram uma tendência de alta irregular, sendo esse um comportamento típico de uma série não estacionária.

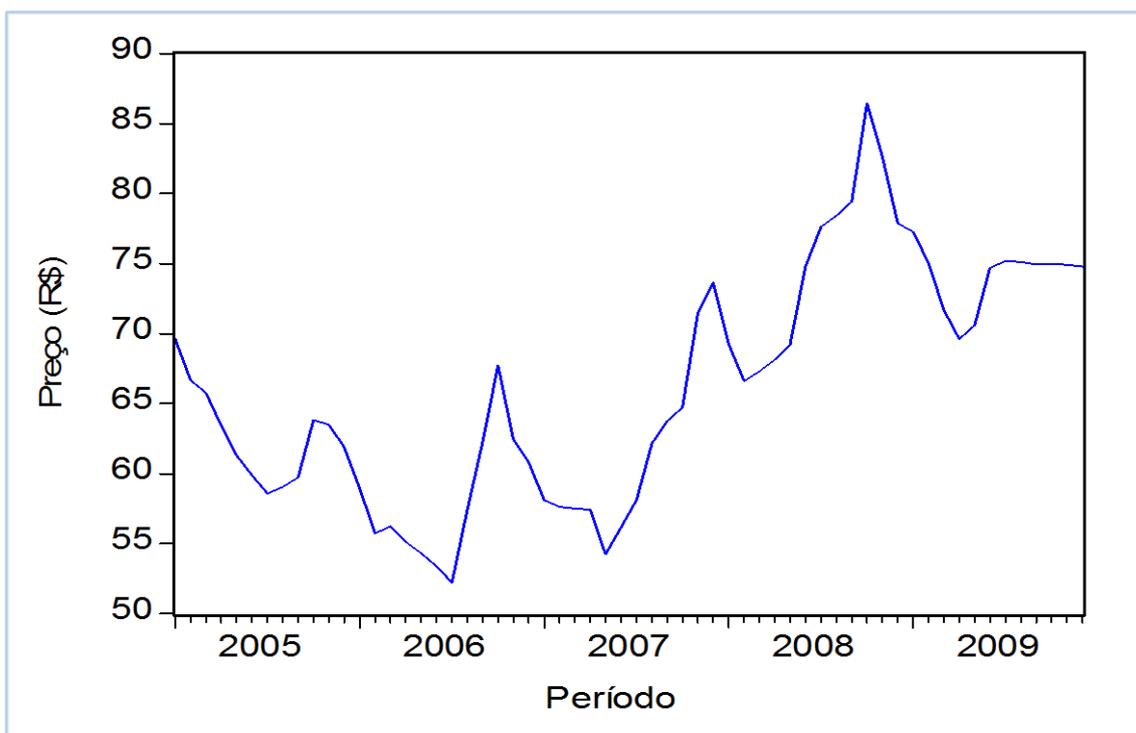


Figura 3 - Série de preços do boi gordo em Campos dos Goytacazes, 01/2005 a 12/2009.  
Fonte: ANUALPEC (2010).

Como os modelos de previsão ARMA necessitam que a série de preços seja estacionária, aplicou-se nos dados o teste de raiz unitária ADF para verificar se a mesma é estacionária. Pelo teste de raiz unitária, verificou-se que a série de preço é não estacionária, pois o valor do teste calculado (estatística t) de -3,03 é menor, em valor absoluto, do que os valores críticos de -4,12; -3,49 e -3,17, ao nível de 1%, 5% e 10%, respectivamente (Tabela 1).

Tabela 1: Teste de raiz unitária ADF da série de preços original.

Nível de Significância	Valores Críticos	Estatística
1%	-4,12	-3,03
5%	-3,49	
10%	-3,17	

Fonte: Resultados da pesquisa.

Dado que a série de preços é não estacionária, utilizou-se a primeira diferença nos dados com intuito de adequar a série para a estimação dos modelos ARIMA e SARIMA. Analisando a Tabela 2, o coeficiente estimado da estatística para a série em primeira diferença foi de -5,53, ou seja, é maior (em módulo) que os pontos críticos, inclusive ao nível de significância estatística de 1%, sendo a série de preços em primeira diferença estacionária, ou seja, integrada de ordem 1, I(1) (Tabela 2).

Tabela 2: Teste de raiz unitária da série de preços na primeira diferença.

Nível de Significância	Valores Críticos	Estatística
1%	-2,61	-5,53
5%	-1,95	
10%	-1,61	

Fonte: Resultados da pesquisa.

Identificada a ordem de integração da série ( $d$ ), o próximo passo foi identificar o número de termos auto-regressivos ( $p$ ) e o número de termos de média móvel ( $q$ ) no modelo. Para isso, foi usada a Função de Autocorrelação (FAC) e a Função de Autocorrelação Parcial (FACP).

A Figura 4 apresenta a FAC e a FACP obtidas para as séries de preços em nível. Observa-se que a FAC inicia com um valor alto e diminui gradualmente, tendo 11 defasagens fora do intervalo de confiança de 95%, o que deixa os coeficientes estatisticamente diferentes de zero. O que é um indicativo de não estacionariedade. Observa-se também pela Figura 4 que a FACP possui quatro defasagens fora do intervalo de confiança.

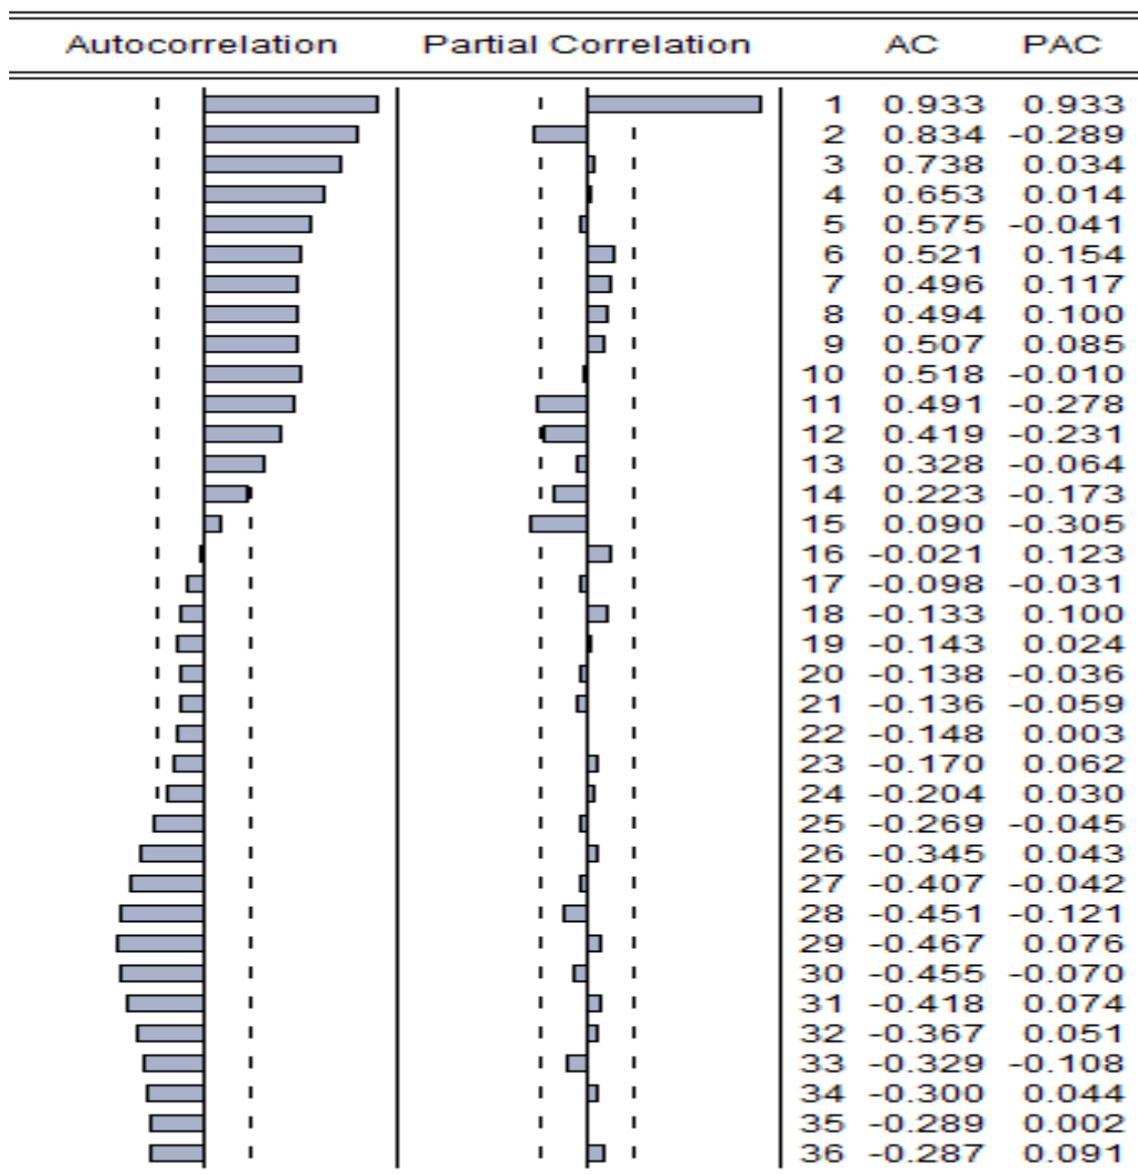


Figura 4 - Função de Autocorrelação (FAC/AC) e de Autocorrelação Parcial (FACP/PAC) da série em nível.

Fonte: Resultados da pesquisa.

Diante desse resultado, obteve-se também a FAC e FACP da série de preços em primeira diferença (Figura 5). Os resultados mostraram que a FAC da primeira diferença da série não apresenta características de uma série não estacionária, corroborando o teste de raiz unitária ADF.

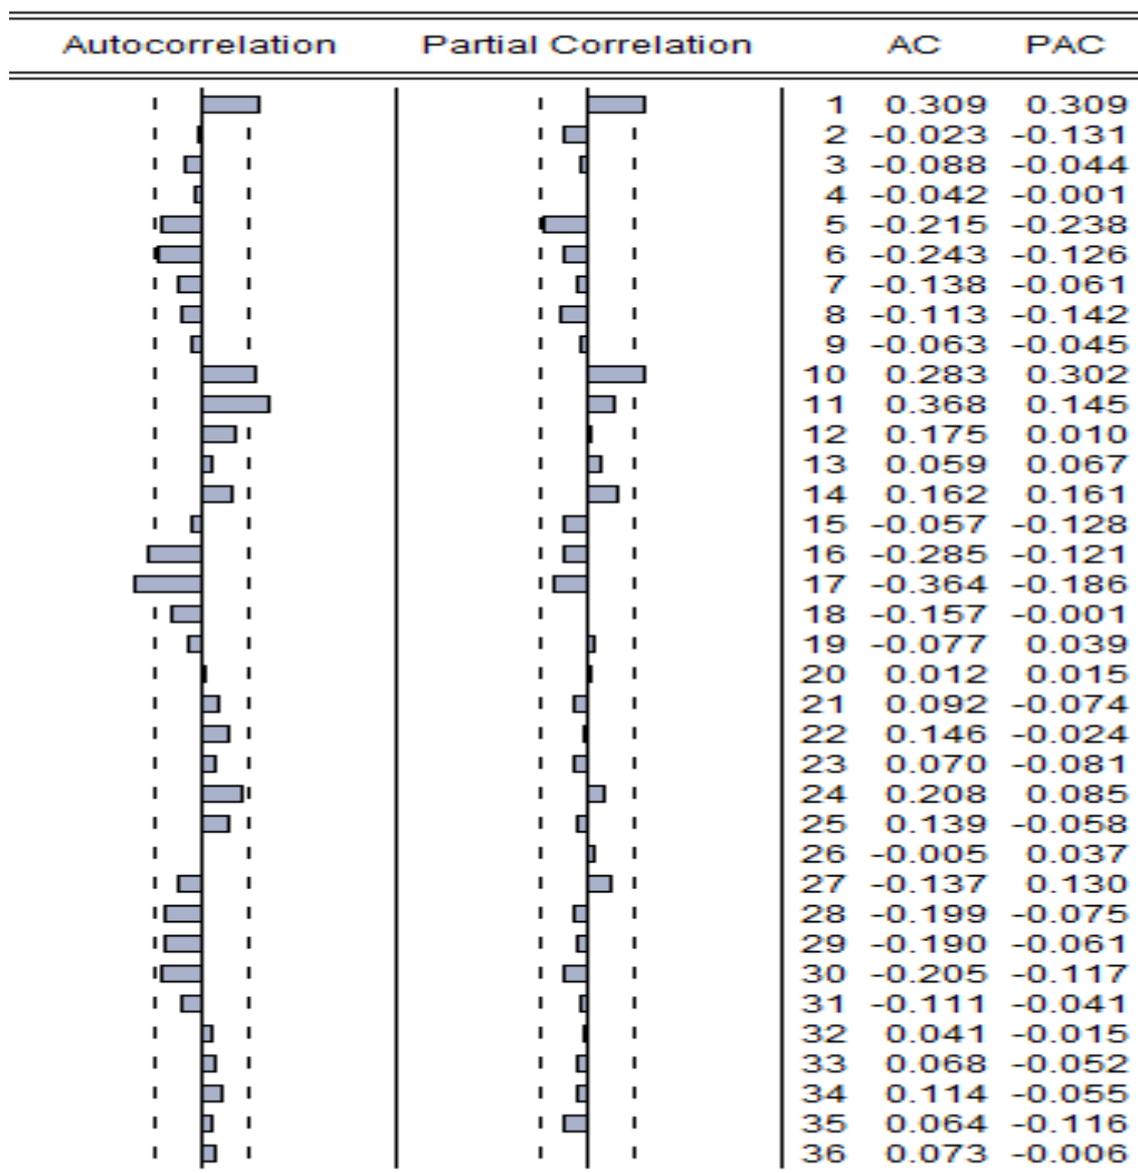


Figura 5 - Funções de Autocorrelação (FAC/AC) e de Autocorrelação Parcial (FACP/PAC) da série em diferença.

Fonte: Resultados da pesquisa.

Assim, usando a FAC e a FACP, foram identificados os modelos a serem estimados. Conforme Gujarati (2000), essas funções e os correlogramas resultantes são as principais ferramentas de identificação dos modelos ARIMA. Segundo o autor, no

caso da FAC e da FACP o que se deve procurar é a similaridade entre as FAC e FACP teóricas e as amostrais, de forma que essas mostrem a direção para a identificação dos modelos, o que requer uma grande habilidade.

Nesse sentido, foi identificado um modelo ARIMA (10,1,0), contendo apenas termos auto-regressivos, visto que a FAC da série em diferença teve um padrão senoidal e a FACP da série em diferença apresentou picos nas defasagens. O modelo citado possui então dois componentes auto-regressivos, referentes às defasagens 1 e 10 da FACP, que estão fora do intervalo de confiança.

Depois de identificado o modelo, esse foi estimado. Pela Tabela 3 pode-se notar que o modelo ARIMA (10,1,0) teve bom ajustamento com todas as defasagens estatisticamente significativas a 10%, exceto para o termo intercepto. Além disso, a equação teve uma estatística F estatisticamente significativa a 1%.

Tabela 3: Resultado da estimação do modelo ARIMA (10,1,0).

Variáveis	Coefficiente	Erro padrão	Estatística t	P-valor
C	1,270223	2,429734	0,522783	0,6045
AR(1)	0,288473	0,152868	1,887074	0,0677
AR(10)	0,490036	0,166615	2,941117	0,0058
R <sup>2</sup>	0,260914	Prob. (Est. F)	0,005859	

Fonte: Resultados da pesquisa.

Pelo fato da FAC ter apresentado um comportamento senoidal indicando a existência de um comportamento sazonal na série de preços, o que já era esperado devido ao preço do boi estar relacionado às variações sazonais, foi também estimado um modelo SARIMA.

Conforme Medeiros *et al.* (2006), quando uma série apresenta um componente periódico deve-se acrescentar uma componente sazonal ao modelo ARIMA, o qual passa a ser denominado modelo SARIMA, que é construído usando a mesma metodologia empregada para a estimação do modelo ARIMA.

Assim, buscou-se modelar novamente a série de preços a fim de obter um modelo SARIMA que se adequasse aos dados. Para isso, realizou-se a diferenciação sazonal da série de preços. A Figura 6 apresenta as novas FAC e FACP obtidas.

Conforme as Figuras, foi estimado um modelo SARIMA (12,1,12)(0,1,1), uma vez que as funções apresentaram picos nas defasagens 2 e 12 (Figura 6).

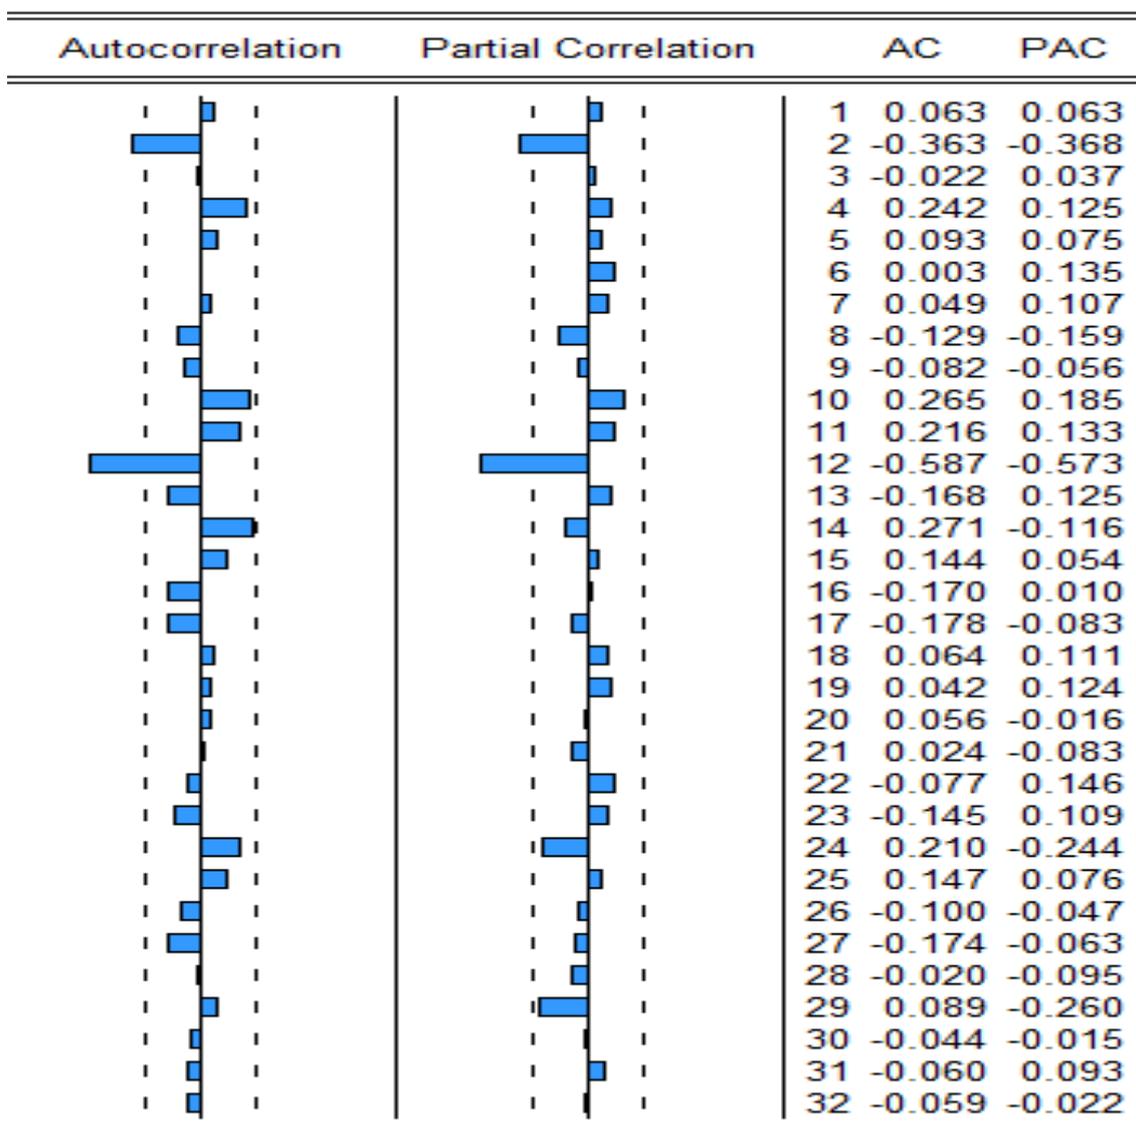


Figura 6 - Funções de Autocorrelação (FAC/AC) e de Autocorrelação Parcial (FACP/PAC) da série em diferença sazonal.

Fonte: Resultados da pesquisa.

O modelo estimado SARIMA (12,1,12)(0,1,1) teve um bom ajustamento sendo todas as variáveis auto-regressivas e de média móvel estatisticamente significativas a 10%. Além disso, a estatística F foi significativa a 1% (Tabela 4). Nota-se também que a defasagem MA(2) não foi incluída no modelo, pois ela não foi estatisticamente significativa a 10%.

Tabela 4: Resultados da estimação do Modelo SARIMA (12,1,12)(0,1,1).

Variáveis	Coefficiente	Erro padrão	Estatística t	P-valor
C	0,333176	0,353147	0,943447	0,3579
AR(2)	-0,390393	0,224115	-1,741934	0,0986
AR(12)	-0,800471	0,136824	-5,850373	0,0000
MA(12)	0,919490	0,035777	25,70025	0,0000
SMA(1)	0,511337	0,118972	4,297956	0,0004
$R^2$	0,903686	Prob,(Est, F)	0,000000	

Fonte: Resultados da pesquisa.

Com a finalidade de checar o ajuste dos modelos, realizou-se o teste de raiz unitária ADF para os resíduos dos modelos gerados, com objetivo de indentificar se esses resíduos são estacionários. Os resíduos mostraram-se estacionários, sendo os modelos adequados para a realização das previsões de preços. A Tabela 5 apresenta os resultados do teste de raiz unitária, os quais não identificaram raízes unitárias nas séries de resíduos.

Tabela 5: Teste de raiz unitária ADF para os resíduos dos modelos estimados.

Nível de Significância	Valores Críticos	ARIMA	SARIMA
1%	-2,61	-7,29	-4,36
5%	-1,95		
10%	-1,61		

Fonte: Resultados da pesquisa.

Após a checagem do modelo, foi realizada as previsões e obtidos os preços previstos e o EQMP para cada modelo. Para efeito de melhor comparação, as novas previsões foram apresentas juntamente com os preços observados no mercado, como pode ser visto na Tabela 6.

Tabela 6: Resultado da eficácia dos modelos de previsões.

Mês	Preço observado	ARIMA	SARIMA
jan/09	77,27	76,62	78,55
fev/09	75,00	77,25	75,86
mar/09	71,65	74,49	71,98
abr/09	69,63	70,81	70,27
mai/09	70,60	69,19	70,69
jun/09	74,71	71,05	75,88
jul/09	75,19	76,09	76,48
ago/09	75,12	75,49	75,02
set/09	74,94	75,26	75,29
out/09	74,97	75,05	76,76
nov/09	74,92	75,14	75,05
dez/09	74,80	75,06	75,70

Fonte: Resultados da pesquisa.

Assim, os resultados mostram que o modelo SARIMA (12,1,12)(0,1,1) teve as melhores previsões, uma vez que apresentou o menor EQMP (Tabela 7).

Tabela 7: Erro Percentual de Previsão (EPP) e Erro Quadrado Médio de Previsão (EQMP).

Mês	ARIMA	SARIMA
EQMP	5,928	0,842

Fonte: Resultados da pesquisa.

#### 4. CONCLUSÃO

A análise dos preços agrícolas é de crucial importância para a empresa rural. Ela permite que o empresário avalie com mais precisão o retorno da atividade agrícola e o risco de perdas financeiras ocasionadas frequentemente por oscilações desfavoráveis dos preços dos produtos e dos fatores de produção.

O planejamento agrícola e dos preços permite que o produtor rural alocue melhor seus recursos, elevando as margens de retorno do capital investido e diminua os riscos da atividade. Assim, o monitoramento dos preços e suas projeções oferecem ao administrador elementos indispensáveis ao negócio agrícola.

Nesse sentido, o artigo teve como objetivo avaliar a eficácia dos modelos de série temporais ARIMA (Auto-Regressivo Integrado de Médias Móveis) e SARIMA (Modelo Sazonal Auto-Regressivo Integrado de Médias Móveis) na previsão dos preços

em campos dos Goytacazes. Para isso, foi usada a metodologia de *Box-Jenkins* para a modelagem desses modelos e usada a série de preços do boi gordo nessa localidade, sendo o poder de previsão dos modelos medido pela estatística Erro Quadrado Médio de Previsão (EQMP).

Seguindo a metodologia de estimação dos modelos, foram identificados dois modelos de previsão de preço: ARIMA (10,1,0) e SARIMA (12,1,12)(0,1,1); sendo que o modelo SARIMA teve a melhor performance, sendo capaz de minimizar de forma mais eficiente o EQMP. O melhor desempenho desse modelo deve-se ao fato dele considerar o componente sazonal presente na série de preços.

Por fim, conclui-se que os modelos são eficazes na previsão dos preços do boi gordo e que podem ser usados como ferramentas de apoio a tomada de decisão dos pecuaristas de Campos dos Goytacazes-RJ. Portanto, os modelos possuem a capacidade de reduzir o risco inerente à atividade, possibilitando uma melhor gestão e maiores ganhos.

## 5. REFERÊNCIAS BIBLIOGRÁFICAS

ANUALPEC. **Anuário da Pecuária Brasileira**. São Paulo: FNP Consultoria & Comércio, 2010. 360 p.

ARÊDES, A. F. Relação de causalidade entre os preços de carnes no varejo. **Informações Econômicas (Impresso)**, v. 39, p. 66-72, 2009.

BOX, G. P.; JENKINS, G. M. **Time series analysis: forecasting and Control**. New York: Holden Day, p.575, 1976.

BRESSAN, A. A.; LIMA, J. E.. Modelos de Previsão de Preços aplicados aos contratos futuros de boi gordo na BM&F. **Nova Economia**, v. 12, p. 117-140, 2003.

GUJARATI, D. N. **Econometria básica**. 3 ed. São Paulo: Pearson Makron Books, 2000. 846 p.

IEL; CNA; SEBRAE. **Estudo sobre a eficiência econômica e competitiva da cadeia agroindustrial da pecuária de corte no Brasil**. Brasília: IEL. 414p. 2000.

IGREJA, A. C. M. **Evolução da pecuária bovina de corte no estado de São Paulo no período de 1969-1984**. Piracicaba. 197 p. Dissertação (mestrado) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, 1987.

KASSOUF, A. L. Previsão de preços na pecuária de corte do Estado de São Paulo. Piracicaba. 102 p. Dissertação (mestrado) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, 1988.

MEDEIROS, A. L.; MONTEVECHI, J. A. B. **Modelagem da equação de previsão do preço da arroba de boi gordo através da regressão linear múltipla**. XII SIMPEP – Bauru, SP, Brasil, 7 a 9 de Novembro de 2005.

MEDEIROS, A. L.; MONTEVECHI, J. A. B.; REZENDE, M. L.; REIS, R. P. **Modelagem ARIMA na previsão do preço da arroba do boi gordo**. In: XLIV Congresso da Sociedade Brasileira de Economia e Sociologia Rural, 2006, Fortaleza. XLIV Congresso da Sociedade Brasileira de Economia e Sociologia Rural. Fortaleza: SOBER, 2006. v. 1.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. São Paulo: Edgard Blücher, 2004. 535 P.

PACHECO, A. G. F. **Estudo da influência de variáveis meteorológicas no aparecimento de casos graves de leptospirose em Salvador-BA via modelos de séries temporais**. Rio de Janeiro. 122 p. Dissertação (mestrado) – Escola Nacional de Saúde Pública, 2001.

PONCIANO, N. J.; SOUZA, P. M.; MATA, H. T. C.; VIEIRA, J. R.; MORGADO, I. F.. Análise de viabilidade econômica e de risco da fruticultura na região norte fluminense. **Revista de Economia e Sociologia Rural**, Brasília - DF, v. 42, n. 4, p. 615-635, 2004.

SCHOUCHANA, F.; CAFFAGNI, L. C. Fatores que determinam o preço do bezerro. **Resenha BM&F**, n. 143, 67-75 p. 2001.

VALE, S. M. L. R.; SILVA JÚNIOR, A. G.; COSTA, F. A. ERU 430: **Administração rural**. Viçosa: Universidade Federal de Viçosa, 2002. 143 p. (Apostila).

WOILER, S.; MATHIAS, W. F. **Projetos: planejamento, elaboração e análise**. São Paulo: Atlas, 1996. 294 p.