

Área: Sustentabilidade | Tema: Produção, Cadeia de Suprimento e Logística Sustentável

**PREVISÃO DO PREÇO DO BOI GORDO NO ESTADO DO RIO GRANDE DO SUL POR MEIO DE
ANÁLISE DE SÉRIES TEMPORAIS**

**FAT CATTLE FORECASTING PRICE ON RIO GRANDE DO SUL STATE USING TIME SERIES
ANALYSIS**

Luiza Antonia Cunha, Tamires Fernanda Barbosa Nunes e Roselaine Ruviano Zanini

RESUMO

O Brasil se destaca no cenário mundial como um dos países que mais produzem carne bovina, o que torna de extrema importância a utilização de um método de previsão da produção para auxiliar no controle e planejamento da produção a fim de ajustá-la de acordo com a demanda e as oscilações mundiais. A presente pesquisa tem por objetivo encontrar um modelo de curto prazo para previsões futuras do preço do boi gordo no Estado do Rio Grande do Sul (RS). A metodologia Box-Jenkins foi utilizada para modelagem ARIMA dos dados mensais do preço do boi gordo no estado, considerando o período de janeiro de 2005 a maio de 2018. O critério penalizador AIC definiu o modelo mais adequado ao ajuste dos dados da série temporal, sendo o melhor modelo o SARIMA (1,1,0) (1,1,0)₁₂, o qual possibilitou captar os movimentos sazonais dos valores defasados, projetando-os nos valores futuros e que também apresentou o menor MAPE(1,98%) indicando que o modelo pode ser considerado apto para prever preços futuros do boi gordo no estado. A fim de verificar a validade do modelo proposto para previsão do preço do boi gordo foi realizada a projeção de preços para valores fora da amostra utilizada na modelagem, o qual corresponde o período do junho a novembro de 2018. O modelo estabelecido se mostrou preciso com média de erro entre as observações de 0,0523. A presente pesquisa buscou auxiliar os produtores de proteína animal a compreender a formação de preço de forma mais abrangente e considerar a importância de ferramentas estatísticas de previsão como suporte a tomada de decisões auxiliando no planejamento e gerenciamento de toda cadeia produtiva do setor pecuarista.

Palavras-Chave: Box-Jenkins, Séries Temporais, Preço Boi Gordo.

ABSTRACT

Brazil stands out on the world stage as one of the countries that most production beef, which makes it extremely important to use a production forecasting method to assist in the control and planning of production in order to adjust it according to world demand and fluctuations. The present research aims to find a short-term model for future forecasts of cattle prices in the state of Rio Grande do Sul (RS). The Box-Jenkins methodology was used ARIMA modeling of the monthly data of the fat cattle price in the State, considering the period from January 2005 to May 2018. The AIC penalty criterion defined the most appropriate model for adjusting the time series data, being the best model the SARIMA (1,1,0) (1,1,0)₁₂, which made it possible to capture seasonal movements of lagged values, projecting them into future values and that also presented the lowest MAPE (1.98%) indicating that the model can be considered able to forecast future prices of cattle in the State. In order to verify the validity of the proposed model for forecasting the price of cattle, prices were projected to values outside the sample used in the modeling, which corresponds to the period from June to November 2018. The established model proved to be accurate with error mean between observations of 0.0523. The present research intends to contribute to the producers animal protein to comprehend price formation more comprehensively and to consider the importance of statistical forecasting tools as support for decision making, aiding in planning and management of the entire livestock chain.

Keywords: Box-Jenkins, Time series, Price of fat cattle

PREVISÃO DO PREÇO DO BOI GORDO NO ESTADO DO RIO GRANDE DO SUL POR MEIO DE ANÁLISE DE SÉRIES TEMPORAIS

1 INTRODUÇÃO

Atualmente a produção de carne bovina no Brasil é uma das principais atividades do agronegócio (SERENO et al., 2013). As exportações de carne bovina encerraram 2018 em 1,64 milhão de toneladas, volume 11% superior ao registrado em 2017 (Associação Brasileira das Indústrias Exportadoras de Carnes – ABIEC, 2019). O resultado representa o maior volume já embarcado pelo país, que o consolida como principal exportador mundial da proteína. O recorde também mostra o reconhecimento quanto à qualidade da carne brasileira, onde 30% do que se produz no país é consumido pelo mercado externo.

O preço da carne bovina é determinado por diversos fatores presentes em sua cadeia produtiva importantes para a garantia da qualidade que vão desde os aspectos relacionados à produção, como nutrição, saúde animal e principalmente os insumos. Outro contribuinte na formação do preço da carne bovina na fase de consumo é o preço estabelecido em relação aos produtos concorrentes, bem como as variáveis macroeconômicas (inflação, taxa de juros, câmbio e PIB) que afetam a demanda do produto (ARAUJO; AREDES; SANTOS, 2012). Outros fatores que impactam no preço da *commodities* de carne bovina são: a sazonalidade, saúde animal, queda no preço internacional do produto, inovações na produção, queda nos preços de bens substitutos, além da oferta e demanda. As combinações dessas variáveis tornam os preços mais voláteis, colaborando para maiores incertezas no mercado agropecuário, o qual é um grande influenciador das variações nos preços, que ocorrem a nível regional ou estadual.

Segundo Araujo et al. (2012) 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.

A incerteza é um desafio que possui grande impacto na previsão e formação de preços. O preço do boi gordo em um período futuro pode afetar diretamente o planejamento, os investimentos e a tomada de decisão ao pecuarista. Desta maneira a análise dos preços agrícolas é de crucial importância para que sejam avaliadas com maior 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 que implicam na gestão da atividade empreendida, de modo que o produtor rural aloque melhor seus recursos, elevando as margens de retorno do capital investido e diminuindo os riscos da atividade (ARAUJO et al, 2012).

Os métodos de previsão auxiliam a tomada de decisões por parte dos agentes envolvidos em atividades que necessitam de planejamento, avaliação de políticas e redução da incerteza. Um dos objetivos das previsões econômicas é a redução da incerteza dentro do setor agropecuário, constantemente sujeito a distúrbios irregulares. (BRESSAN, 2004).

No sentido de prever os preços futuros do boi gordo, esta pesquisa tem por objetivo propor um modelo de previsão baseado na extensão do modelo ARIMA (Auto Regressivo Integrado de Médias Móveis) que considerada o efeito da sazonalidade presente nas séries de dados temporais. O modelo SARIMA (Modelo Sazonal Auto Regressivo Integrado de Médias Móveis) foi utilizado para estabelecer um modelo de previsão de curto prazo para realizar projeções futuras do preço do boi gordo no estado do Rio Grande do Sul (RS), considerando o componente sazonal característico deste tipo de dado.

Esta pesquisa escolheu a atividade pecuária ligada a criação de gado devido à elevada importância econômica do setor para o país e, em especial, para o estado do RS. De acordo com a Pesquisa Pecuária Municipal, realizada pelo Instituto Brasileiro de Geografia e Estatística (IBGE) o RS é o sexto maior produtor de gado bovino do Brasil, entre as unidades da federação,

demonstrando a importância do gerenciamento da cadeia produtiva para os pecuaristas no que tange ao planejamento para suprir a demanda e gerenciar as flutuações do mercado nacional e internacional que impactam nos processos produtivos do agronegócio. Esta pesquisa visa contribuir com o gerenciamento de demanda, flutuações do mercado e tomada de decisão do pecuarista a partir de um modelo de previsão de curto prazo que permite modelar a sazonalidade presente nos preços do boi gordo para o estado do Rio Grande do Sul.

2 MATERIAIS E MÉTODOS

A presente pesquisa utilizou para a modelagem um banco de dados coletado no site Agrolink (<https://www.agrolink.com.br/>), com as cotações do preço do boi gordo (kg/vivo) do estado do Rio Grande do Sul. O banco de dados é composto por cento e sessenta e uma (161) observações mensais, no qual a análise inicia em janeiro de 2005 e encerra em maio de 2018.

A metodologia Box-Jenkins utilizada para modelagem dos dados e construção do modelo de previsão do preço de boi gordo no estado do RS se refere a métodos matemáticos para análise e previsões de séries temporais (FOULI et al., 2018; BRESSAN, 2004), genericamente conhecida como modelo ARIMA (*Auto Regressive Integrated Moving Averages*) ou por Auto Regressivos Integrados de Médias Móveis (KIRCHNER; SOUZA; STUMM, 2011). A metodologia possibilita a captação do comportamento da correlação seriada ou auto correlação entre os valores da série temporal, podendo desta forma realizar previsões futuras (SOUZA, 2016; UEDA, 2018).

A construção do modelo ARIMA, segundo a metodologia de Box-Jenkins seguirá as seguintes etapas (VAGROPOULOS et al., 2017; YANG, ZHENG & RUILI, 2017):

1º) Verificação da estacionariedade das observações através da análise gráfica e testes das raízes unitárias ADF – Dickley-Fuller Aumentado (1997) e KPSS – Kwiatkowski, Phillips, Schmidt e Shin (1992) (XINXIANG, BO & HUIJUAN, 2017; SOUZA, 2016).

De acordo com a metodologia Box-Jenkins para estimação do modelo é necessário que a série a ser modelada seja estacionária, assim os parâmetros estimados serão significativos em toda série. Caso a série não seja estacionária será necessário a aplicação de diferenças para torná-la estacionária (MARTIN et al., 2016). Quando a série for não estacionária e necessitar de diferenças com $d \neq 1$ e não inteiro, o modelo utilizado será um ARFIMA (*Autoregressive Fractional Integrated Moving Average*), para este caso o grau de diferenciação deverá estar entre -0,5 e 0,5.

2º) Seleção dos parâmetros AR, MA, ARMA, ARIMA, ARFIMA, SARIMA a serem utilizadas na modelagem das variáveis por meio da análise dos gráficos da Função de Autocorrelação (FAC) e da Função de Autocorrelação Parcial (FACP) que indicam qual filtro de integração deve ser utilizado pela modelagem dos dados através de seus lags significativos.

A modelagem ARIMA permite definir um modelo que melhor represente a série temporal analisada. Um modelo ARIMA de ordem p pode ser descrito conforme o conjunto de equações a seguir (FOULI et al., 2018):

$$\text{ARIMA} \quad \Delta^d Z_t = \mu + \phi_1 \Delta^d Z_{t-1} + \dots + \phi_p \Delta Z_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (1)$$

Em que:

Z_t = representa a série temporal, μ = média do processo, ϕ = parâmetro AR, θ = parâmetro MA, Δ^d = grau de diferenciação necessária para tornar a série estacionária e ε_t = resíduos.

Os modelos ARIMA pressupõe que os valores futuros estão linearmente relacionados com as observações passadas e possuem ruído branco. Quando a auto correlação dos valores da

série não ocorrem em instantes contínuos, se evidenciando um efeito sazonal presente na série temporal os modelos SARIMA apresentam maior acurácia de previsão. O modelo SARIMA representa uma variação do modelo ARIMA no qual o índice S representa a parte sazonal, que busca explicar o efeito sazonal inerente as variáveis (VAGROPOULOS et al., 2017; YANG, ZHENG & RUILI, 2017).

O modelo SARIMA pode ser descrito matematicamente (VAGROPOULOS et al., 2017) pela equação a seguir:

$$\phi_p(B)\Phi_p(B^S)\nabla^d\nabla_s^D y_t = \theta_q(B)\Theta_Q(B^S)\varepsilon_t \quad (2)$$

Onde:

y_t = variável de previsão, $\phi_p(B)$ = parâmetro AR de ordem p , $\theta_q(B)$ = parâmetro MA de ordem q , $\Phi_p(B^S)$ = parâmetro AR sazonal de ordem P , $\Theta_Q(B^S)$ = parâmetro MA sazonal de ordem Q , ∇^d = grau de diferenciação não sazonal e ∇_s^D = diferenciação sazonal.

3º) Definição dos modelos concorrentes, através da observação dos resíduos gerados pelo modelo através dos gráficos FAC e FACP do modelo estimado. Se os gráficos FAC e FACP apresentarem resíduos dentro dos limites de confiança, pode-se considerar que as características de ruído branco foram alcançadas, sendo o melhor modelo possível para previsão dos dados (YANG, ZHENG & RUILI, 2017).

4º) Seleção do modelo que melhor se ajustem as variáveis através dos critérios penalizadores: Critério de Informação de Akaike (*AIC*) e Critério de Informação Bayesiano (*BIC*). Em casos que a série apresentar um conjunto de amostras pequenas, o critério *AIC* apresentará resultados superiores ao critério *BIC* (SOBRAL & GILMAR, 2011).

$$AIC = \ln\hat{\sigma}^2 + n \frac{2}{T} \quad (3)$$

$$BIC = \ln\hat{\sigma}^2 + n \frac{\ln T}{T} \quad (4)$$

Em que:

$\hat{\sigma}^2$ = variância do erro, T = número de observações utilizadas e n = número de parâmetros estimados.

5º) Seleção do melhor modelo através das estatísticas de previsão MAPE e U-Theil. Após definir o modelo que melhor se ajuste à série é necessário avaliar sua acurácia de previsão. As estatísticas de previsão podem ser avaliadas através da utilização dos testes, *Mean Absolute Percent Error* – MAPE (equação 5) e coeficiente U-Theil (equação 6) (TUBINO, 2009).

$$MAPE (\%) = \frac{\sum \left(\frac{e_t}{Z_t} \right)}{n} \times 100 \quad (5)$$

$$U - theil = \frac{\sqrt{\sum_{t=1}^n (e_t)^2}}{\sqrt{\sum_{t=1}^n (Z_t - Z_{t-1})^2}} \quad (6)$$

Onde:

n = número de observações, e_t = erro de previsão e Z_t = valor real observado no instante t .

A etapas da metodologia Box-Jenkins descritas permitiram modelar a série temporal do preço do boi gordo do estado do RS, estabelecendo um modelo de previsão de preços que

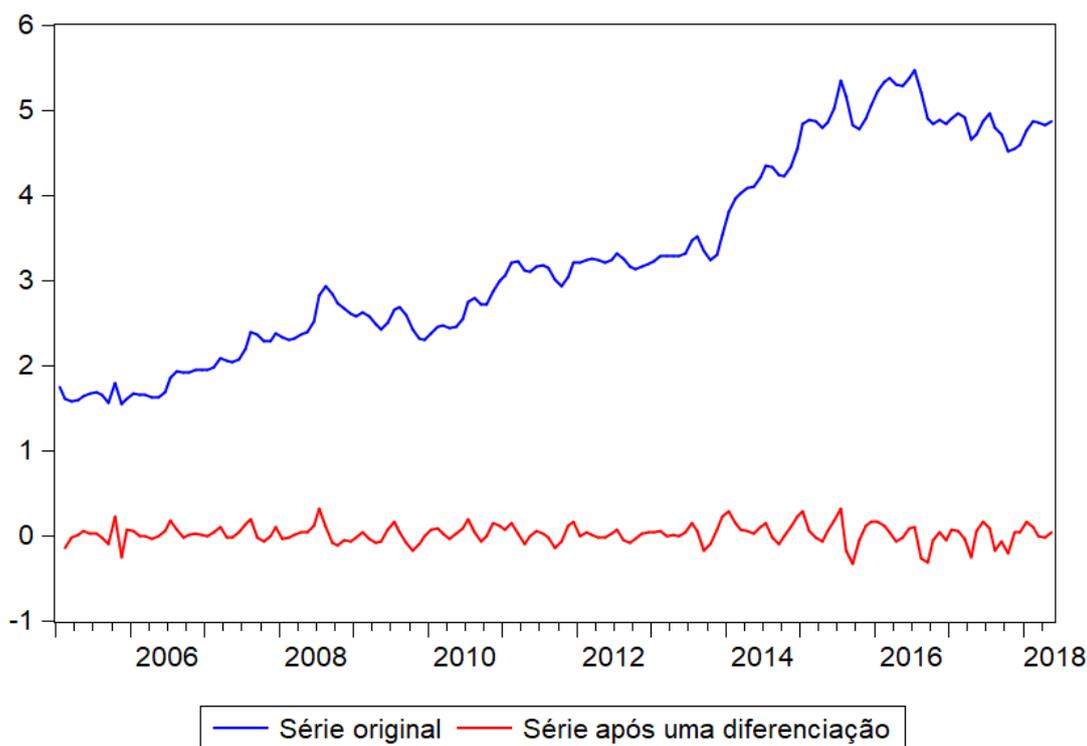
melhor se ajustou aos dados utilizados na modelagem permitindo que projeções futuras sejam realizadas a curto prazo para prever o preço do boi gordo.

3. RESULTADOS

Os dados da presente pesquisa referem-se à série de preços do boi gordo do estado do Rio Grande do Sul, correspondente ao período de janeiro de 2005 a maio de 2018, totalizando 161 observações.

Na análise gráfica da Figura 1(a), pode-se observar que a série temporal analisada no presente estudo é não estacionária, sendo necessário a aplicação de diferenças para torná-la estacionária, sendo esta uma condição para a aplicação dos modelos ARIMA. Além disso, observa-se que a mesma apresenta tendência crescente. Após a aplicação de primeiras diferenças a série se torna estacionária, como pode se observar na Figura 1(b), onde nota-se o efeito da sazonalidade presente nas variáveis.

Figura 1 - (a) Série do preço do Boi Gordo do estado do RS original de janeiro de 2005 a maio de 2018; (b) Série do preço do Boi Gordo do estado do RS após uma diferenciação



Fonte: os autores.

Após a retirada da tendência pelo método das diferenças, observa-se na Figura 1(b) a presença de picos sazonais. A expansão da soja influenciou a produção e conseqüentemente o preço da carne bovina do estado, pode-se observar que em 2005 o pico de preços do boi gordo ocorreu entre setembro e novembro. Os produtores do estado utilizam o período da entressafra da lavoura da soja para plantar azevém e aveia, que se destinam à terminação dos bois, fazendo com que a oferta na saída do boi que antes se concentrava entre abril e maio viesse a acontecer entre setembro e novembro.

O aparecimento de febre aftosa no Mato Grosso no Sul (MS) movimentou a economia interna do estado, podemos observar que após 2005 os preços se estabilizam sutilmente, isso porque o abastecimento interno de carne que antes era feito a partir da carne proveniente do MS ficou restrito a produção do próprio estado. Além disso, o RS passou por períodos de seca, prejudicando os índices de natalidade na cria e diminuindo a lucratividade dos produtores.

Os períodos entre 2015 e 2017 verifica-se uma queda significativa dos preços que se estendem por esse intervalo. A queda nos preços de fertilizantes, herbicidas, dos grãos e o preço estável do combustível contribuiu para que os preços se mantivessem baixos neste período. Estes foram alguns aspectos significativos que influenciaram o preço do boi gordo nos períodos descritos acima. Outros fatores econômicos também exercem influência sobre a formação do preço deste *commoditie*. O indicativo de sazonalidade sugere a utilização de um modelo SARIMA para previsão dos preços, por apresentar o parâmetro sazonal como componente do modelo de previsão.

Para verificar a estacionariedade da série em nível e após a aplicação da primeira diferença foram utilizados os testes de raízes unitárias ADF e KPSS, considerando um nível de significância de 5% ($\alpha=0,05$). Verificando o valor do *p* valor para série em nível do teste ADF, aceitamos a hipótese nula (H_0) de não estacionariedade da série pois *p* valor do teste ADF (0,5825) é maior que valor de α (0,05). A estatística do teste KPSS para a série em nível resultou em 1,467276 sendo maior do que o valor crítico para 5% de confiança (0,463000), demonstrando que se rejeita a hipótese nula (H_0) que neste caso é a aceitação da estacionariedade da série. Aplicando a primeira diferenciação aceita-se a hipótese nula (H_0) para o teste KPSS, verificando a estacionariedade após a primeira diferenciação na qual o valor do teste 0,074024 foi menor que o valor crítico para 5% de confiança (0,463000).

A análise da estacionariedade também pode ser observada pelo comportamento das funções de autorcorrelação (FAC) e autocorrelação parcial (FACP) na Figura 2.

A FAC presente na Figura 2, mostra que os *lags* não decaem exponencialmente para zero, este comportamento de decaimento exponencial lento para zero configura a possível não estacionariedade da série, observando-se a necessidade de utilizar o método de diferenciação para torná-la estacionária.

Figura 2 - Gráficos FAC e FACP da série original do preço do boi gordo no RS

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.985	0.985	158.98	0.000
		2	0.965	-0.139	312.68	0.000
		3	0.947	0.041	461.48	0.000
		4	0.931	0.067	606.25	0.000
		5	0.916	0.023	747.52	0.000
		6	0.902	-0.008	885.33	0.000
		7	0.886	-0.063	1019.1	0.000
		8	0.869	-0.035	1148.6	0.000
		9	0.850	-0.042	1273.3	0.000
		10	0.835	0.111	1394.4	0.000
		11	0.818	-0.113	1511.5	0.000
		12	0.799	-0.050	1624.0	0.000
		13	0.777	-0.109	1731.1	0.000
		14	0.753	-0.041	1832.3	0.000
		15	0.729	-0.022	1927.9	0.000

Fonte: os autores.

O gráfico FACP sugere a utilização de apenas um parâmetro auto regressivo para construção do modelo de previsão.

A Tabela 1 apresenta os modelos concorrentes selecionados após a estimação dos parâmetros pertinentes, baseando-se nos critérios penalizadores *AIC* e *BIC* para seleção do melhor modelo.

Tabela 1 - Parâmetros do modelo concorrente e do modelo ajustado

SARIMA (1,1,0) (1,0,0) ₁₂ *						
d = 1	Parâmetro	Erro Padrão	Estatística <i>t</i>	AIC	BIC	Ruído Branco
ϕ_1	0,280157	0,058432	4,794548	-2,043178	-1,985518	sim
ϕ_{12}	0,605058	0,052795	11,46052			
SARIMA (1,1,0) (1,1,0) ₁₂						
d = 1	Parâmetro	Erro Padrão	Estatística <i>t</i>	AIC	BIC	Ruído Branco
ϕ_1	0,287611	0,06265	4,590779	-1,96599	-1,905236	sim
ϕ_{12}	-0,346583	0,078586	-4,410248			

Fonte: os autores.

*modelo ajustado para série de preços do Boi Gordo no RS.

Observa-se na Tabela 1, o modelo selecionado para representar a série em análise foi o modelo SARIMA (1,1,0) (1,0,0)₁₂. Ambos os modelos apresentaram ruído branco e probabilidade significativa¹. Para a escolha do modelo foi considerado o critério penalizador *AIC*, por apresentar resultados superiores ao *BIC* para amostras pequenas.

O modelo SARIMA (1,1,0) (1,0,0)₁₂ mostra que o preço do boi gordo no Estado do RS apresenta um comportamento sazonal autoregressivo de ordem 12. Após a escolha do melhor modelo a análise dos resíduos foi realizada através dos gráficos FAC e FACP, Figura 3, no qual os resíduos apresentam-se não correlacionados e dentro dos limites de confiança estabelecidos, caracterizando a presença do ruído branco, ou seja, média zero, variância constante e resíduos não autocorrelacionados.

¹ O *p*-valor dos modelos concorrentes estimados foram significativos, ou seja, $p < 0,001$ para todos os parâmetros dos modelos.

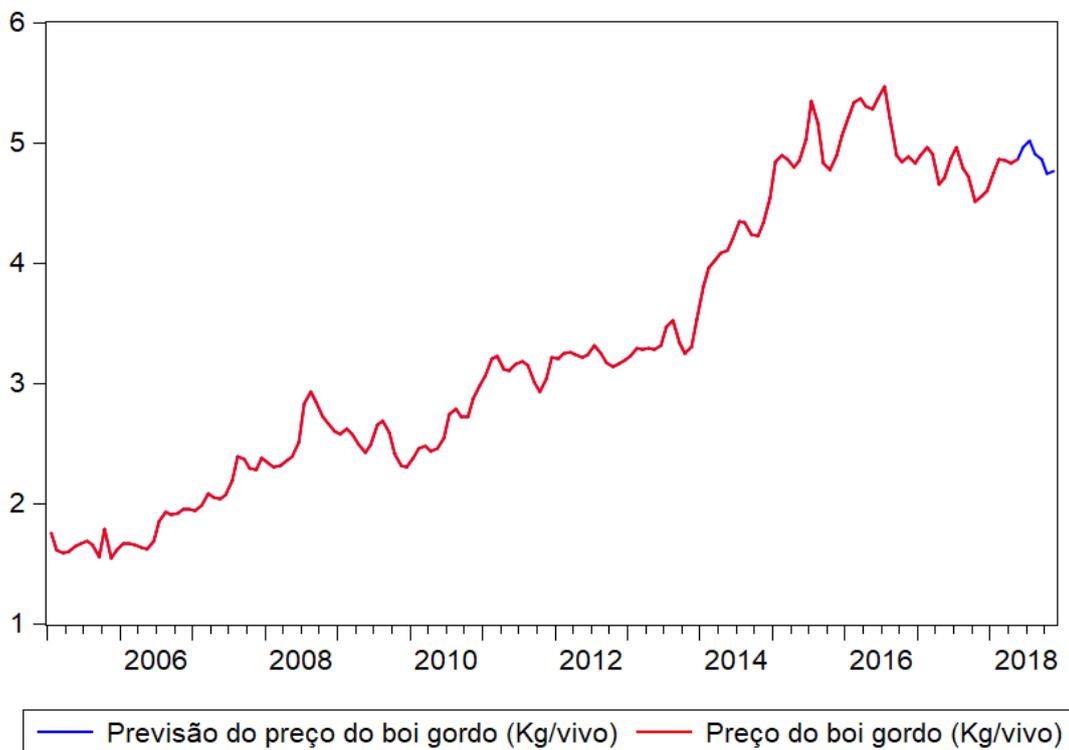
Figura 3 - Gráficos FAC e FACP dos resíduos do modelo selecionado para previsões do preço do boi gordo no estado do RS

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.030	0.030	0.1480	
		2	-0.119	-0.120	2.4573	
		3	-0.083	-0.077	3.5965	0.058
		4	0.131	0.124	6.4345	0.040
		5	-0.018	-0.046	6.4895	0.090
		6	0.091	0.120	7.8912	0.096
		7	0.136	0.149	11.019	0.051
		8	-0.083	-0.098	12.183	0.058
		9	-0.018	0.050	12.241	0.093
		10	-0.043	-0.074	12.567	0.128
		11	0.127	0.091	15.356	0.082
		12	-0.124	-0.131	18.053	0.054
		13	0.077	0.075	19.093	0.059
		14	-0.126	-0.147	21.892	0.039
		15	-0.090	-0.099	23.330	0.038

Fonte: autores

Na Figura 4 pode-se observar as previsões realizadas *in sample*, verificando a adequação do modelo e o comportamento futuro da série.

Figura 4 - Previsão mensal do preço do boi gordo no estado do RS



Fonte: autores.

As estatísticas de previsão MAPE e U-theil foram realizadas a fim de confirmar a adequação do modelo ajustado para série estudada. A estatística MAPE considera os erros em percentual e obteve o valor de 1,986754, indicando que o erro percentual médio do modelo ajustado é baixo. A estatística U-theil resultou no valor de 0,011353, nesta estatística espera-se valores entre 0 e 1, e através do resultado obtido considera-se que o modelo de previsão é adequado para representar a série temporal de preços do boi gordo do estado do RS e realizar projeções de preços futuros.

3 CONCLUSÃO

Os métodos de previsão de preço se tornam ferramentas fundamentais capazes de contribuir com os pecuaristas na gestão e tomada de decisão, considerando o retorno futuro sobre investimentos, o atendimento as expectativas do mercado e as variações de toda cadeia produtiva. Deste modo, a metodologia Box & Jenkins é uma ferramenta eficaz para construção de modelos de previsão de séries temporais.

O modelo SARIMA permite captar os efeitos sazonais presentes nos preços, sendo o modelo que melhor se ajustou ao preço do boi gordo no RS. Segundo os critérios utilizados no presente estudo, o modelo SARIMA (1,1,0) (1,0,0)₁₂ foi selecionado como melhor modelo, demonstrando que o preço do boi gordo no estado do RS apresenta um comportamento sazonal autoregressivo de ordem 12, ou seja, o período de janeiro do ano anterior influencia o período de janeiro do ano corrente, desta forma o fenômeno observado se repetirá a cada 12 meses. Por exemplo, o preço de janeiro de 2018 influenciou no preço de janeiro de 2019. As constantes oscilações dos preços do boi gordo ressaltam a necessidade de ferramentas capazes de modelar essas variações oportunizando a previsão de expectativas futuras.

A fim de verificar a validade do modelo proposto para previsão do preço do boi gordo foi realizada a projeção de preços para valores fora da amostra utilizada na modelagem. A previsão foi realizada para o período do junho a novembro de 2018, o modelo estabelecido se mostrou preciso na projeção dos preços com média de erro entre as observações de 0,0523, desta forma podemos verificar que o modelo proposto acompanhou o comportamento do mercado.

Os produtores precisam estar atentos as expectativas do mercado, as variáveis econômicas nacionais e internacionais capazes de influenciar a formação do preço a fim de ajustar sua produção à demanda existente, permitindo que o lucro seja maximizado. Atualmente, com a peste suína africana as projeções do mercado consideram que os preços globais de proteína animal (bovina, suína e de frango) tendem a aumentar até 2020 em 5,6%, ilustrando que além das variáveis econômicas nacionais que norteiam a cadeia produtiva do setor agropecuário é necessário considerar índices internacionais que impactam diretamente na formação de preço de proteína animal no país. O Brasil se destaca no cenário mundial como um dos países que mais produzem carne bovina, o que torna de extrema importância a utilização de ferramentas estatísticas para projeções futuras visando ajustar a produção à demanda e oscilações mundiais do mercado do agronegócio.

Para trabalhos futuros, sugere-se a utilização dos modelos ARMAX que corresponde aos modelos Auto Regressivos Integrados de Médias móveis que permite inserir variáveis exógenas na modelagem e previsão. Desta forma, poderá ser analisada as variáveis exógenas que implicam diretamente sobre o preço do boi gordo, assim aumentará a assertividade dos resultados, podendo projetar os valores de acordo com as oscilações das variáveis de influência.

REFERÊNCIAS

ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS EXPORTADORAS DE CARNES – ABIEC. Disponível em: < <http://www.abiec.com.br/Default.aspx> >. Acessado em 19 de julho de 2019.

AGROLINK. Disponível em: <<https://www.agrolink.com.br/cotacoes/>>. Acessado em 27 de março de 2019.

ARAÚJO, S. J.; AREDES, A. F.; SANTOS, V. F. **Previsão de preços do boi gordo com modelos ARIMA E SARIMA.** Revista de Economia, Anápolis, v.8, n.2, p. 27-44, jul./dez. 2012.

BRESSAN, A. A. **Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais.** RAE-eletrônica, v. 3, n. 1, 2004.

CADENA, E; RIVERA, W. **Wind speed forecasting in three different regions of Mexico, using a hybrid ARIMA - ANN model.** Renew. Energy, v.35, n. 12, p. 2732-2738, 2010.

FOULI, H. et al. **Seasonal Forecasting of Rainfall and Runoff Volumes in Riyadh Region, KSA.** KSCE Journal of Civil Engineering, v.22, n. 7, p. 2637-2647, 2018.

GOMES, T. E. O. **Utilização do Software R para Previsão de Preço do Dia Seguinte de uma Série Temporal.** UNOPAR Cient. Exatas Tecnologia, v. 13, n. 1, p. 61-68, 2014.

KIRCHNER, R.; SOUZA, A. M.; STUMM, E. M. F. **A Modelagem Como Ferramenta De Gestão.** Latin American Journal of Business Management. v. 2, n. 1, p. 223, 2011.

LIMA, R. C.; GÓIS, M. R.; ULISES, C. **Previsão de preços futuros de commodities agrícolas com diferenciações inteira e fracionária, e erros heteroscedásticos.** RER, Rio de Janeiro, v. 45, n. 3, p. 621-644, 2007.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting: Methods and Applications.** 3. ed. United States of America: Ed. Wiley e Sons, 1998.

MARTIN, A. C.; HENNING, E.; WALTER, O. M. F. C.; KONRATH, A. C. **Análise de séries temporais para previsão da evolução do número de automóveis no Município de Joinville.** Revista Espacios, v. 37, n. 06, 2016.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULACHI, M. **Introduction to Time Series Analysis and Forecasting.** Nova Jersey: John Wiley e Sons, 2008.

NORONHA, M. O.; SOUZA, A. M.; ZANINI, R. R. **Aplicação da metodologia Box & Jenkins para modelagem da emissão de Certificados ISO 14001 no Brasil.** Revista ESPACIOS, v. 37, n. 12, 2016.

SERENO, F. L et al. **Determinação do Padrão de Variação Estacional dos Preços Futuros de Boi Gordo Entre os Anos de 2002 e 2012.** In: X Congresso Online – Administração. 2013. Disponível em: <http://www.convibra.org/award.asp?ev=30&lang=pt>. Acesso em 18 de jun. de 2019.

SOBRAL, T. E. L.; BARRETO, G. **Análise dos critérios de informação para seleção de dados de ordem em modelos auto regressivos.** In: X Conferência Brasileira de Dinâmica, Controle e Aplicações. 2011.

SOUZA, F. M. **Modelos De Previsão: aplicações à energia elétrica - ARIMA- ARCH-AI e ACP.** Curitiba: Appris, 2016. ISBN 9788547302481.

TUBINO, D.F. **Planejamento E Controle Da Produção: Teoria E Prática.** 2. Ed. São Paulo: Atlas, 2009.

UEDA, R. M. et al. **Combinação de técnicas de previsão de demanda: aplicação em uma agroindústria de nutrição animal.** Exacta-EP, São Paulo, v. 16, n. 2, p. 83-93, 2018.

VAGROPOULOS, S. I. et al. **Comparison of SARIMAX, SARIMA, modified SARIMA and ANN-based models for short-term PV generation forecasting.** In: IEEE International Energy Conference (ENERGYCON), Leuven, Belgium, 4-8 apr. 2016.

YANG, Y.; ZHENG, H.; ZHANG, R. **Prediction and analysis of aircraft failure rate based on SARIMA model.** IN: IEEE International Conference on Computational Intelligence and application, Beijing, China, 8-11 sept. 2017.

XINXIANG, Z.; BO, Z.; HUIJUAN, F. **A comparison study of outpatient visits forecasting effect between ARIMA with seasonal index and SARIMA.** In: International Conference on Progress in Informatics and Computing (PIC), Nanjing, China, 15-17 dec. 2017.