

Metodologia de Séries Temporais como ferramenta de análise na produção de frangos no Brasil

Denise A. Paiva^{1†}, Ana Cláudia F. Herval², Thelma Sáfyadi³

¹Universidade Federal de Lavras-UFLA

²Universidade Federal de Lavras-UFLA. E-mail: anafestucci@outlook.com.

³Universidade Federal de Lavras-UFLA. E-mail: safadi@des.ufla.br.

Resumo: *O presente trabalho apresenta a análise da série de abate de frangos (quantidade) desde 2000 até 2018. Esse estudo é relevante uma vez que o Brasil é o segundo maior produtor de carne de frango do mundo. Uma metodologia útil para analisar estes dados é a análise de séries temporais, com a qual pode-se verificar o aumento ou diminuição do abate ao longo do tempo, ajustar modelos e realizar previsões satisfatórias. Para esta análise, foram verificadas a aditividade do modelo, assim como a presença das componentes tendência e sazonalidade. Foi utilizada a modelagem de modelos da classe SARIMA (ARIMA sazonal). Os modelos considerados adequados à série foram comparados através das funções de perda das previsões, o Erro Quadrático Médio de Previsão e o Erro Médio Absoluto Percentual e em relação aos critérios de informação. Foi observado que a quantidade de frangos abatidos apresenta um crescimento (aparentemente linear) para então, a partir de 2016, começar a decair. De fato, a previsão para 2019 confirmou que os valores tendem a diminuir.*

Palavras-chave: Séries temporais; abate de frangos; modelos de Box & Jenkins.

Abstract: *The present study presents the analysis of the broiler slaughter series (quantity) from 2000 to 2018. This study is relevant since Brazil is the second largest producer of chicken meat in the world. A useful methodology to analyze these data is the analysis of time series, where it can be verify the increase or decrease of the slaughter over time, adjust models and make satisfactory predictions. For this analysis, the additivity of the model, as the presence of trend and seasonal components are verificated. Modeling of the SARIMA (Seasonal ARIMA) class was used. The models considered adequate to the series were compared through the prediction loss functions, the Mean Prediction Error and the Mean Absolute Percentual Error and for the information criteria. It was observed that the number of broiler slaughter presented a growth (apparently linear) by then, starting in 2016, began to decline. In fact, the forecast for 2019 has confirmed that the values tend to decrease.*

Keywords: Time series; broiler slaughter; Box & Jenkins models.

[†]Autor correspondente: denisepaiva1310@gmail.com.

Introdução

A indústria avícola apresentou um grande desenvolvimento nas últimas décadas, destacando-se no mercado interno e externo da agroindústria. O Brasil se encontra como o segundo maior produtor de carne de frango do mundo, com cerca de 13,05 milhões de toneladas produzidas em 2017, sendo 33,1% destinado à exportação e 66,9% para o mercado interno. O estado de Santa Catarina foi o que mais se destacou no abate de frangos no ano de 2017, representando 16,21% do total (ABPA, 2018).

Esse avanço é decorrente, principalmente, do intenso processo de seleção realizado nos programas de melhoramento genético, do uso de cruzamento entre raças, originando linhagens específicas com características próprias. Além disso, o uso de práticas eficientes de manejo ambiental, nutrição adequada e controle sanitário, permitiram a evolução do setor avícola ao longo do tempo.

Os resultados do melhoramento genético trouxeram impactos expressivos na dinâmica da cadeia produtiva avícola por meio do aperfeiçoamento de características de carcaça e desempenho. Com o objetivo de agregar valor ao produto e atender a demanda do consumidor, as aves destinadas a produção de carne, conhecidas como frangos de corte, foram selecionadas principalmente para as características peso ao abate, peso de peito e conversão alimentar, o que proporcionou avanços na taxa de crescimento destes animais (GAYA et al., 2006).

O estudo acerca da quantidade de abate de frangos tem grande importância, já que está diretamente relacionado às práticas de consumo e alimentação da população no decorrer dos anos, tendo em vista que o Brasil se destaca como um dos maiores produtores. Devido a grande importância da avicultura na economia nacional e seu impacto na cadeia produtiva mundial de carne de frango, justifica-se a aplicação de técnicas estatísticas para o estudo das séries históricas do abate de frangos de corte no agronegócio brasileiro.

Neste contexto, por se tratar de dados observados ao longo do tempo, insere-se a metodologia de Séries Temporais. Além de propiciar uma melhor compreensão do seu comportamento ao longo dos últimos anos, a análise de séries temporais utilizada para avaliar o mercado avícola, em termos de abate, pode ser uma ferramenta útil no controle do sistema de produção, possibilitando atuar preventivamente em possíveis flutuações na produção e planejamento dos processos. Sendo assim, este trabalho tem como objetivo analisar a série da quantidade de abate de frangos entre os anos de 2000 e 2018, utilizando os dados do segundo semestre de 2018 para verificação do ajuste e, enfim, realizar previsões para o ano de 2019. Desta maneira, será possível verificar a evolução do setor enquanto importante contribuinte para os avanços da agroindústria brasileira.

Material e métodos

Os dados utilizados foram coletados no site do Ipeadata, referentes à quantidade de abate de frangos no Brasil no período de janeiro de 2000 à dezembro de 2018. A unidade coleta todos os estabelecimentos que efetuam a atividade de abate de animais e estão sob inspeção federal, estadual ou municipal, ou seja, não está sendo considerado o abate clandestino (Ipeadata, 2019).

Inicialmente, uma análise gráfica é realizada para verificar as componentes de tendência e sazonalidade. Porém, antes de fazer qualquer inferência sobre as componentes da série, é necessário verificar se o modelo é aditivo ou multiplicativo. Em caso de confirmação do

modelo multiplicativo, usa-se a transformação logarítmica.

Um gráfico usualmente utilizado para verificar a necessidade de transformação dos dados traz no eixo das abscissas as médias das observações de subconjuntos da série original e no eixo das ordenadas, a amplitude desses subconjuntos. Quando a amplitude independe das médias, os pontos ficam espalhados ao redor de uma reta paralela ao eixo das abscissas. Um teste t para testar a hipótese de que o coeficiente de inclinação da reta é zero, indicará a necessidade de transformação quando retornar um valor-p inferior à 0,05. Diferentes inclinações desta reta indicam necessidade de diferentes transformações. A mais comum delas, a transformação logarítmica é sugerida quando a inclinação é próxima de 0,5 (Jenkins, 1979).

Para testar a existência da componente tendência pode-se utilizar o teste de Cox-Stuart (ou teste do Sinal), o qual divide a série em duas partes, formando pares de observações que serão comparados. De acordo com Morettin & Toloí (2006), para a aplicação de tal teste as observações devem ser agrupadas em pares $(Y_1, Y_{c+1}), \dots, (Y_{N-c}, Y_N)$, em que $c = \frac{N}{2}$ se N for par e $c = \frac{N+1}{2}$ se N for ímpar, sendo N o número de observações da série. A cada par (Y_i, Y_{i+c}) , associa-se o sinal de + para $(Y_i < Y_{i+c})$ e o sinal de - para $(Y_i > Y_{i+c})$, eliminando os empates. Então, definindo n o número de pares em que $Y_i \neq Y_{i+c}$ temos as seguintes hipóteses:

$$\begin{cases} H_0 : P(Y_i < Y_{i+c}) = P(Y_i > Y_{i+c}), \forall i, & \text{ou seja, não existe tendência;} \\ H_1 : P(Y_i < Y_{i+c}) \neq P(Y_i > Y_{i+c}), \forall i, & \text{ou seja, existe tendência.} \end{cases}$$

Para $n \leq 20$ a regra de decisão é baseada na distribuição binomial e para $n > 20$ utiliza-se a aproximação da normal.

Para verificar a presença da componente sazonalidade pode-se utilizar o teste não paramétrico de Kruskal-Wallis, no qual a hipótese H_0 de não existência de sazonalidade é rejeitada se a estatística dada por

$$T_1 = \frac{12}{N(N+1)} \sum_{j=1}^k \frac{R_j^{*2}}{n_j} - 3(N+1),$$

for maior ou igual ao valor crítico T_{1c} , onde T_{1c} é tal que $P_H(T_1 \geq T_{1c}) = \alpha$, α é o nível de significância do teste. Para n_j suficientemente grande, ou $k \geq 4$, sob H_0 , a distribuição de T_1 pode ser aproximada por uma variável χ^2 com $k - 1$ graus de liberdade, sendo k o número de amostras de tamanho n_j .

Para eliminar a componente de tendência, frequentemente uma ou duas diferenças na série já são suficientes para a sua eliminação. A componente sazonal, assim como a tendência, pode ser eliminada por meio de diferença. Neste caso, é necessário que se conheça o período s para o qual se define o padrão de repetição (por exemplo, $s = 12$ meses quando o padrão se repete ano a ano ou $s = 3$ meses, para padrões trimestrais). Como na eliminação da tendência, é possível eliminar a componente sazonal fazendo uma diferença na série da ordem do período s . Neste caso, a série é dita dessazonalizada.

Eliminadas as componentes tendência e sazonalidade, a série se torna estacionária. A estacionariedade é uma suposição muito importante para o ajuste de algumas classes de modelos, isto quer dizer que a série se desenvolve aleatoriamente em torno de uma média constante.

A partir daí, pode-se então ajustar um modelo para série estacionária. Também conhecidos como modelos paramétricos de Box & Jenkins (1976), os modelos ARIMA (auto-

regressivos integrados e de médias móveis) são frequentemente utilizados devido aos bons resultados em previsões com ajuste sazonal.

Para a construção do modelo, é preciso considerar as fases de identificação de um modelo baseado nas funções de autocorrelação (FAC) e autocorrelação parcial (FACP); em seguida a estimação dos parâmetros do modelo identificado; e, por fim, a verificação do modelo ajustado através de uma análise de resíduos. Nesta última etapa, verifica-se se os mesmos são correlacionados ou se são ruído branco. Neste último caso, o modelo é adequado. Porém, caso contrário, volta-se à fase de identificação e repete-se todo o processo.

Conforme Box & Jenkins (1976), um modelo do tipo SARIMA(p, d, q)(P, D, Q) $_s$ (ou ARIMA Sazonal), de período s , pode ser representado pelo seguinte polinômio:

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

em que

$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ é o operador autorregressivo de ordem p ;

$\Phi(B^s) = 1 - \Phi_1 B - \dots - \Phi_P B^P$ é o operador autorregressivo sazonal de ordem P ;

$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ é o operador de médias móveis de ordem q ;

$\Theta(B^s) = 1 - \Theta_1 B - \dots - \Theta_Q B^Q$ é o operador de médias móveis de ordem Q ;

$(1-B)^d$ é o operador diferença, sendo d o número de diferenças simples aplicadas à série;

$(1-B^s)^D$ é o operador diferença sazonal, sendo D o número de diferenças sazonais aplicadas à série.

A especificação dos modelos que se ajustam à série pode ser realizada por meio dos gráficos das funções de autocorrelação (FAC) e autocorrelação parcial (FACP). Para então, com o modelo definido, estimar os parâmetros através do método de máxima verossimilhança.

O teste de Ljung & Box (1978) pode ser usado para verificar a adequabilidade dos modelos ajustados, ou seja, verificar se os resíduos são independentes e identicamente distribuídos (iid), podendo então ser denominados de ruído branco. A estatística do teste é dada por:

$$Q(k) = n(n+2) \sum_{j=1}^k \frac{\hat{r}_j^2}{n-j},$$

em que a estatística do teste tem uma distribuição χ^2 aproximadamente com $k-p-q$ graus de liberdade, n é o número de observações da série, k é o k -ésimo lag, $p-q$ é o número de parâmetros do modelo e \hat{r} são os resíduos estimados. Não se rejeita a hipótese nula H_0 quando $Q(K) < \chi_{k-p-q}^2$ e, neste caso, o resíduo pode ser considerado um ruído branco.

Os modelos ajustados em que se obtém um resíduo ruído branco são comparados usando o Critério de Informação de Akaike (AIC). O AIC é dado por:

$$AIC(k, l) = \ln(\hat{\sigma}_{k,l}^2) + \frac{2(k+l)}{N},$$

Sigmae, Alfenas, v.8, n,2, p. 227-237, 2019.

64ª Reunião da Região Brasileira da Sociedade Internacional de Biometria (RBRAS).

18º Simpósio de Estatística Aplicada à Experimentação Agronômica (SEAGRO).

em que $\hat{\sigma}_{k,l}^2$ é o estimador de máxima verossimilhança da variância residual do modelo considerado. Além do AIC, pode-se utilizar outros critérios de informação, como o Critério de Informação Bayesiano (BIC) e o Critério de Hanna-Quinn (HQC). De acordo com esses critérios, o melhor modelo ajustado é aquele que apresenta os menores valores.

Com o modelo selecionado e ajustado, este pode ser utilizado para realizar as previsões sobre as observações futuras. De acordo com Morettin & Toloí (2006), a previsão de Z_{t+h} para $h = 1, 2, \dots$, é definida como a esperança condicional de Z_{t+h} dados todos os valores passados. Desse modo,

$$\hat{Z}_t(h) = E[Z_{t+h}|Z_t, Z_{t-1}, \dots].$$

Finalizando a previsão, a adequabilidade do modelo pode ser de acordo com a Média Percentual Absoluta do Erro (MAPE) e o Erro Quadrático Médio de Previsão (EQMP), ou seja, o melhor modelo é aquele que apresentar os menores valores de MAPE e EQMP. As expressões para obtenção de EQMP e MAPE são dadas por

$$EQMP = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| 100\%.$$

Todas as análises realizadas foram utilizando o software Gretl (GRETl, 2019) e o software R (R Core Team, 2018), como o ajuste dos modelos, análise de resíduos e previsão.

Resultados e discussões

Inicialmente, utilizamos os dados da série de quantidade de abate de frangos no Brasil referente ao período de janeiro de 2000 até junho de 2018, reservando os valores referentes ao segundo semestre de 2018 que serão utilizados para verificar e validar o modelo ajustado. Posteriormente, para realizar a previsão para o ano de 2019, toda análise foi realizada novamente utilizando a série completa, de 2000 à 2018, com todas as 228 observações.

O gráfico da série, apresentado na Figura (1a) foi construído para se observar o comportamento da quantidade de abate de frangos no Brasil ao longo do tempo no período especificado.

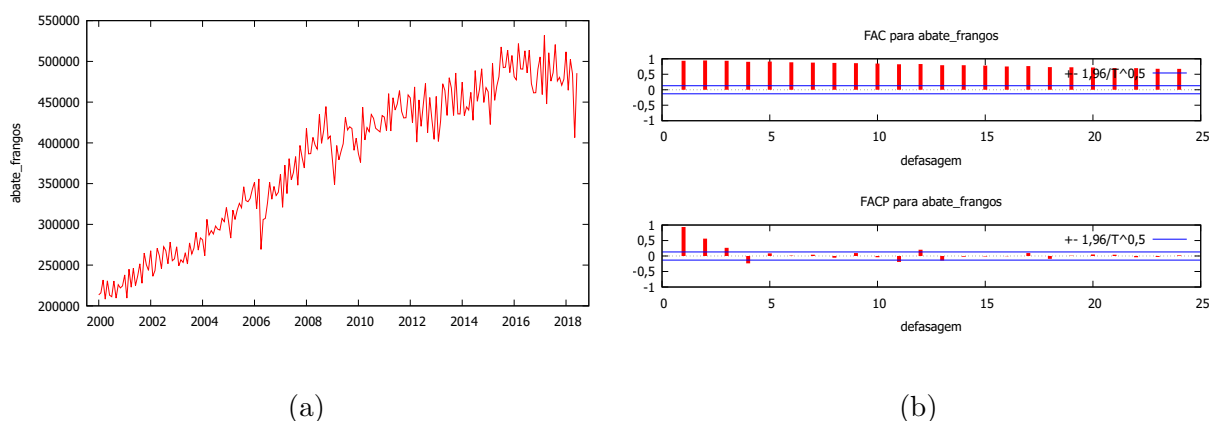


Figura 1: (a) Série da quantidade de abate de frangos (período jan/2000 - jun/2018). (b) Correlograma com as funções de autocorrelação e autocorrelação parcial desta série. Fonte: Produzido pelo autor

Observa-se um crescimento ao longo do tempo, dando indicativo de uma componente de tendência. Além disso, através do correlograma apresentado na Figura (1b) nota-se que a série é não estacionária, uma vez que a FAC decai lentamente para zero.

Para verificar a necessidade de transformação dos dados, construiu-se o gráfico de amplitude-média. Ao aplicar o teste t, no qual testa-se a hipótese nula de que o coeficiente de inclinação da reta é zero, obteve-se um valor-p de 0,00185. Desta maneira, aplica-se a transformação logarítmica já que é possível confirmar que existe necessidade de transformação dos dados.

Ao analisar o valor-p $< 0,001$ obtido para o teste de Cox-Stuart, pode-se concluir que a componente tendência está presente no modelo, sendo necessário aplicar a primeira diferença na série original para retirá-la.

Na Figura 2 encontram-se o gráfico e o correlograma da série log diferenciada.

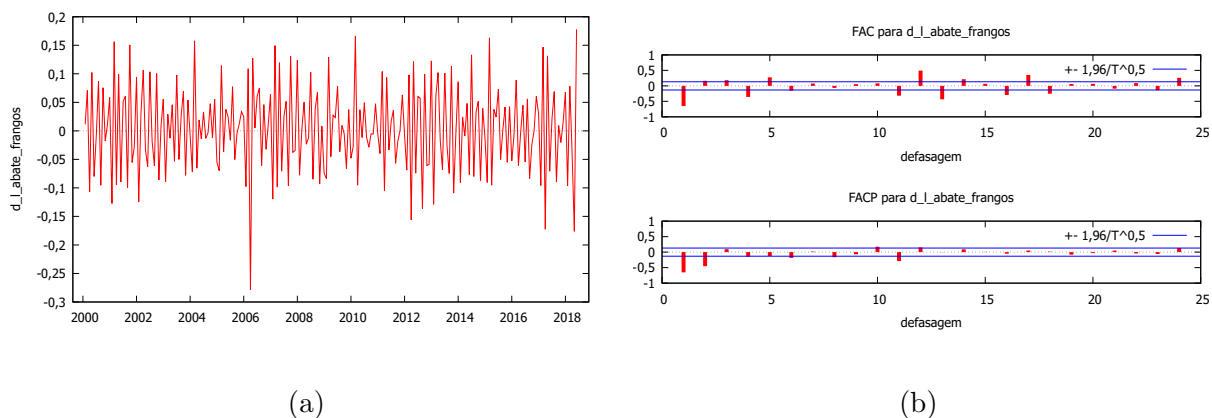


Figura 2: (a) Série log diferenciada. (b) Correlograma da série log diferenciada.
Fonte: Produzido pelo autor

O teste não paramétrico de Kruskal-Wallis foi realizado e obteve-se um valor-p de 0,9701. Desta forma, não se rejeita a hipótese nula de não existência de sazonalidade determinística, entretanto, apresenta a sazonalidade estocástica, uma vez que verifica-se que os *lags* múltiplos de 12 estão fora do intervalo de confiança quando se analisa o correlograma da série diferenciada (figura 2b), indicando a necessidade do acréscimo da componente sazonal.

Também com base no correlograma da série estacionária (figura 2b), foi possível propor alguns modelos para a mesma. Entre os vários modelos cujos resíduos foram ruído branco, optou-se por continuar a análise com dois modelos: aquele que apresentou menor número de parâmetros e aquele que apresentou o menor valor para os Critérios de Informação (AIC, BIC e HQC).

Na Tabela 1 encontram-se as informações desses dois modelos citados, bem como as estimativas dos coeficientes correspondentes com os respectivos valores-p. Já os valores obtidos para os Critérios de Informação estão apresentados na Tabela 2.

Os modelos propostos foram corretamente ajustados, uma vez que os resíduos provenientes dos ajustes são ruído branco, constatados a partir do teste de autocorrelação de Ljung-Box que, com 24 *lags* forneceu estatística de teste e valores-p (indicados entre parênteses) iguais a $Q(24) = 22,5712(0,2568)$ e $Q(24) = 27,8249(0,1136)$, respectivamente para os Modelos 1 e 2.

Como queremos verificar a validação dos modelos, comparamos as previsões obtidas

Tabela 1: Modelos escolhidos adequados aos dados e seus respectivos coeficientes estimados e valor-p correspondente.

Modelo		Coeficientes estimados	Valor-p
SARIMA(5, 1, 0)(1, 0, 0) ₁₂	ϕ_1	-0,794065	< 0,001
	ϕ_2	-0,297327	< 0,001
	ϕ_4	-0,276191	< 0,001
	ϕ_5	-0,181016	0,0076
	Φ_1	0,396663	< 0,001
SARIMA(2, 1, 4)(0, 0, 1) ₁₂	ϕ_1	-0,831210	< 0,001
	ϕ_2	-0,320918	< 0,001
	θ_4	-0,247127	< 0,001
	Θ_1	0,344666	< 0,001

Fonte: Produzido pelo autor

Tabela 2: Modelos ajustados aos dados e seus respectivos valores AIC, BIC e HQC.

Modelo	AIC	BIC	HQC
SARIMA(5, 1, 0)(1, 0, 0) ₁₂	-706,8520	-686,4630	-698,6193
SARIMA(2, 1, 4)(0, 0, 1) ₁₂	-703,5598	-686,5689	-696,6992

Fonte: Produzido pelo autor

para os Modelos 1 e 2 utilizando as 6 observações reservadas anteriormente. Os gráficos das figuras (3a) e (3b) mostram essas previsões com o intervalo de 95% de confiança representado pelo sombreado, enquanto os valores obtidos para as funções de perda EQMP e MAPE estão apresentados na Tabela 3.

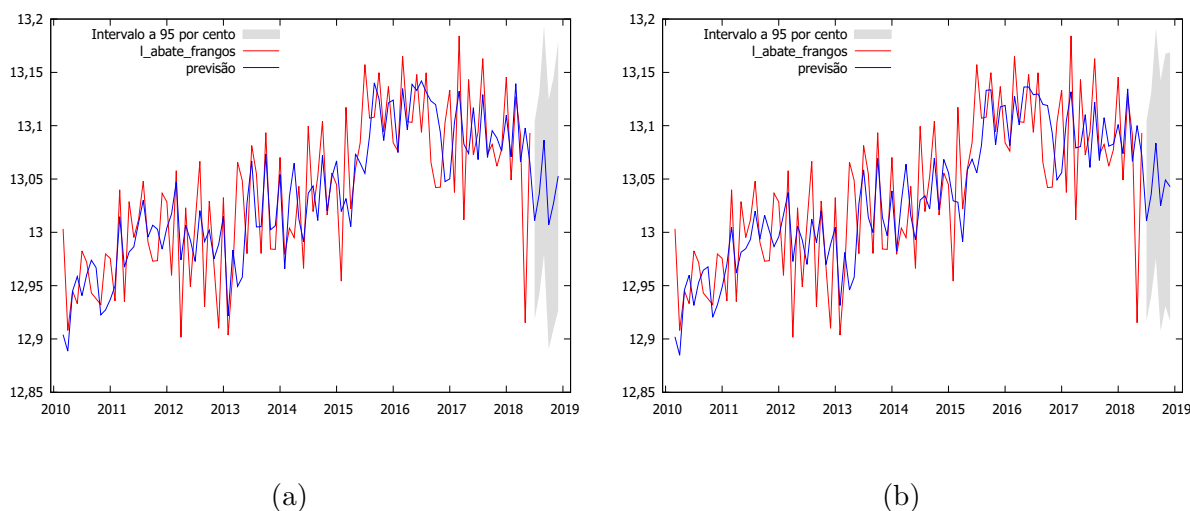


Figura 3: Gráficos das séries efetivo×ajustado com previsões para os Modelos 1(a) e 2(b).
Fonte: Produzido pelo autor

Analisando os valores apresentados na Tabela 3, o Modelo 2 - SARIMA(2, 1, 4)(0, 0, 1)₁₂ forneceu os menores valores para ambas as funções de perda. Desta forma, este foi o modelo escolhido e é dado por

$$(1 - \phi_1 B - \phi_2 B^2)(1 - B) \log(Z_t) = (1 - \theta_4 B^4)(1 - \Theta_1 B^{12}) a_t.$$

Sigmae, Alfenas, v.8, n,2, p. 227-237, 2019.

64ª Reunião da Região Brasileira da Sociedade Internacional de Biometria (RBRAS).
18º Simpósio de Estatística Aplicada à Experimentação Agronômica (SEAGRO).

Tabela 3: Modelos propostos e seus respectivos valores de EQMP e MAPE.

Modelo	EQMP	MAPE
SARIMA(5, 1, 0)(1, 0, 0) ₁₂	1.258.979.910,84	5,83%
SARIMA(2, 1, 4)(0, 0, 1) ₁₂	1.071.546.247,08	4,99%

Fonte: Produzido pelo autor

Utilizando as estimativas dos coeficientes da Tabela 1, o modelo final proposto para os dados de abate de frangos para previsões é

$$(1 + 0,831B + 0,321B^2)(1 - B)\log(Z_t) = (1 + 0,247B^4)(1 - 0,345B^{12})a_t.$$

A Tabela 4 apresenta quais foram os valores obtidos pelo Modelo 2 para a produção nos meses de julho à dezembro de 2018, bem como os valores reais, o erro padrão e o intervalo de confiança de 95%. Desta forma, confirma-se a validação do modelo.

Tabela 4: Valores previstos para a quantidade de abate de frangos para o período de julho de 2018 à dezembro de 2018.

Meses	Valores reais	Valores de previsão	Erro padrão	Intervalo de Confiança 95%
Jul/2018	470995,151	447122,104	1,049	407072,670 - 491111,761
Ago/2018	506899,033	458528,625	1,049	416903,892 - 504309,275
Set/2018	448530,250	480992,04	1,056	431853,634 - 535721,652
Out/2018	501885,050	453658,958	1,062	403382,693 - 510201,487
Nov/2018	464696,500	464674,296	1,062	412752,739 - 523127,762
Dez/2018	449897,894	461735,733	1,066	407093,839 - 523711,375

Fonte: Produzido pelo autor

Partimos então para um novo ajuste de modelo, agora com todos os dados, referente a janeiro de 2000 à dezembro de 2018, para, enfim, fazer a previsão para o ano de 2019. Ressaltamos que, assim como para o primeiro ajuste, as etapas de transformação dos dados, presença das componentes tendência e sazonalidade, retirada das componentes presentes no modelo foram verificadas.

Apesar da inclusão de novas 6 observações na série de dados, o modelo SARIMA(2, 1, 4)(0, 0, 1)₁₂ continuou sendo um bom ajuste, além de ter sido o modelo validado anteriormente. Na Tabela 5 encontram-se as novas estimativas para os coeficientes do modelo citado, bem como os respectivos valores-p. Os valores obtidos para os Critérios de Informação estão apresentados na Tabela 6.

O modelo proposto foi corretamente ajustado, já que os resíduos provenientes do ajuste são ruído branco, constatados a partir do teste de autocorrelação de Ljung-Box que forneceu estatística de teste $Q(24) = 29,69$ e valor-p = 0,07504.

Desta forma, o modelo escolhido para previsão é dado por

$$(1 + 0,833B + 0,318B^2)(1 - B)\log(Z_t) = (1 + 0,219B^4)(1 - 0,352B^{12})a_t.$$

Tabela 5: Coeficientes estimados e respectivos valores-p para o modelo ajustado aos dados de jan/2000 à dez/2018.

Modelo		Coeficientes estimados	Valor-p
SARIMA(2, 1, 4)(0, 0, 1) ₁₂	ϕ_1	-0,833015	< 0,001
	ϕ_2	-0,317724	< 0,001
	θ_4	-0,219281	< 0,001
	Θ_1	0,352125	< 0,001

Fonte: Produzido pelo autor

Tabela 6: Critérios de informação e respectivos valores para o modelo ajustado aos dados de jan/2000 à dez/2018.

AIC	-717,5447
BIC	-700,4200
HQC	-710,6346

Fonte: Produzido pelo autor

A seguir, apresentamos o gráfico (Figura 4) com a previsão na parte sombreada e a Tabela 7 com os valores obtidos pelo Modelo de Previsão (SARIMA(2, 1, 4)(0, 0, 1)₁₂ com os dados completos) para a produção nos meses de janeiro à dezembro de 2019, além do erro padrão e o intervalo de confiança de 95%.

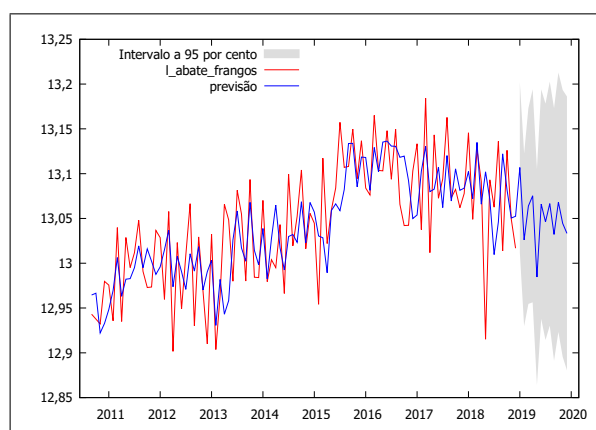


Figura 4: Gráfico da série efetivo \times ajustado para o Modelo de Previsão.

Fonte: Produzido pelo autor

Considerações finais

Os modelos de séries temporais mostraram-se adequados para ajustar a série formada pelas quantidades mensais de abate de frangos no Brasil. Além disso, observou-se a presença da componente tendência na série, indicando um crescimento ao longo do tempo e também, a presença da sazonalidade estocástica mostrando que a série apresentava a componente sazonal variando com o tempo.

A previsão realizada para o segundo semestre de 2018 mostrou-se satisfatória através

Sigmae, Alfenas, v.8, n,2, p. 227-237, 2019.

64ª Reunião da Região Brasileira da Sociedade Internacional de Biometria (RBRAS).

18º Simpósio de Estatística Aplicada à Experimentação Agronômica (SEAGRO).

Tabela 7: Valores previstos para a quantidade de abate de frangos para o período de jan/2019 à dez/2019.

Meses	Valores de previsão	Erro padrão	Intervalo de Confiança 95%
Jan/2019	492329,7530	1,041	447723,8880 - 541379,0720
Fev/2019	454100,1285	1,050	412415,6587 - 499998,3113
Mar/2019	471573,8516	1,057	422775,6758 - 526004,4754
Abr/2019	477009,6499	1,062	423534,8161 - 537236,1313
Mai/2019	435658,5181	1,063	386258,0699 - 491376,5416
Jun/2019	472610,0931	1,067	415810,5388 - 537168,4438
Jul/2019	463353,7128	1,061	406081,8422 - 528702,9384
Ago/2019	472846,9301	1,072	412644,2002 - 541832,3959
Set/2019	456881,3463	1,075	396858,8679 - 525981,3317
Out/2019	473623,5089	1,076	409788,7246 - 547402,6956
Nov/2019	462568,9935	1,079	398574,2167 - 536838,7237
Dez/2019	457395,1696	1,081	392565,6251 - 532930,8727

Fonte: Produzido pelo autor

da validação do modelo SARIMA(2, 1, 4)(0, 0, 1)₁₂. Para realizar a previsão para o ano de 2019, o modelo ajustado anteriormente mostrou-se adequado e foi mantido. O modelo para previsão confirmou a queda na quantidade de abate de frangos, observado a partir de 2016 pelo gráfico da série.

Agradecimentos

Agradecimento a CNPq, CAPES e Fapemig.

Referências Bibliográficas

ABPA. Associação Brasileira de Proteína Animal. *Relatório anual 2018*. 176p, 2018.

AKAIKE, H. A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, vol.AC-19, n.6, p.716-723, 1974.

BOX, G.E.P.; JENKINS, G.M. *Time Series Analysis: Forecasting and Control*. San Francisco: HoldenDay, 1970 (Revised edition, 1976).

COTTRELL, A.; LUCCHETTI, R. *Gnu Regression, Econometrics and Time-series Library*. Disponível em: < <http://gretl.sourceforge.net/pt.html> >. Acesso em 18 de março de 2019.

GAYA, L.G.; FERRAZ, J.B.; REZENDE, F.M.; MOURÃO, G.B.; MATTOS, E.C.; ELER, J.P.; MICHELAN FILHO, T. Heritability and genetic correlations estimates for performance, carcass and body composition traits in a male broiler line. *Poultry*

Sigmae, Alfenas, v.8, n,2, p. 227-237, 2019.

64ª Reunião da Região Brasileira da Sociedade Internacional de Biometria (RBRAS).
18º Simpósio de Estatística Aplicada à Experimentação Agronômica (SEAGRO).

Science. v.85, n.5, p.837-843, 2006.

HANNAN, E.J.; QUINN, B.G. The determination of the order of autoregression. *Journal of the Royal Statistical Society. Series B (Methodological)*, 41, n.2, p.190-195, 1979.

Ipeadata. Instituto de Pesquisa Econômica Aplicada. Disponível em: http://ipeadata.gov.br/beta3/#/dados-serie?anomapa=&ascOrder=&base=macro&busca=&columnOrdering=&end=2018&fonte=&serid=ABATE12_ABQUFR12&skip=0&start=2000&tema=Produ%C3%A7%C3%A3o&territoriality=. Acesso em 18 de março de 2019.

JENKINS, G.M. *Practical Experiences with Modelling and Forecasting Time Series*. Jersey, Channel Islands: GJP Publications, 1979.

LJUNG, G.M.; BOX, G.E.P. On a measure of lack of fit in time series models. *Biometrika*, v.65, n.2, p.97-303, 1978.

MORETTIN, P.A.; TOLOI, C.M.C. *Análise de Séries Temporais*. 2ª ed. São Paulo: E. Blucher, 2006, 538p.

R Core Team (2018). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.

SCHWARZ, G. Estimating the dimension of a model. *Annals of Statistics*, v.6, n.2, p.461-464, 1978.

Sigmae, Alfenas, v.8, n,2, p. 227-237, 2019.

64ª Reunião da Região Brasileira da Sociedade Internacional de Biometria (RBRAS).
18º Simpósio de Estatística Aplicada à Experimentação Agronômica (SEAGRO).