Artigo DOI: 10.14295/2238-6416.v76i1.823

ESTUDO COMPARATIVO ENTRE OS MODELOS DE PREVISÃO ARIMA E ETS PARA DADOS TEMPORAIS DA PRODUÇÃO DE LEITE NO BRASIL

Comparative study between ARIMA and ETS forecast models for temporal data on milk production in Brazil

Larissa Maria Martinello[1], Samuel Bellido Rodrigues[1], Tásia Hickmann[1], Jairo Marlon Corrêa[1], Levi Lopes Teixeira[1]*

RESUMO

A produção de leite está em constante crescimento, pois movimenta a economia e é fonte de renda para diversas famílias. Um eficaz planejamento das atividades executadas tanto por parte dos produtores de leite como dos laticínios está diretamente relacionado às expectativas em relação à produção anual do leite. A estimativa da produção de leite pode ser abordada por meio de modelos numérico-estatísticos de previsão, com auxílio de *softwares* como o R. Dessa forma, o presente artigo aborda uma análise comparativa da previsão de produção de leite industrializado no Brasil, por meio dos modelos ARIMA (*Autoregressive Integrated Moving Average* – Autorregressivo Integrado de Médias Móveis) e ETS (*Error, Trend, Seasonal* – Erro, Tendência, Sazonal). A determinação dos modelos e demais cálculos estatísticos foram realizados por meio do *software* livre R para séries de dados mensais e trimestrais da produção de leite, obtido pelo site do IBGE, no período de 2004 a 2018. Os modelos forneceram as previsões para o ano de 2019 e estes foram comparados com valores reais. As métricas utilizadas foram o MAPE (*Mean Absolute Percentage Error* – Erro Percentual Médio Absoluto), RMSE (*Root Mean Square Error* – Raiz do Erro Médio Quadrático) e MAE (*Mean Absolute Error* – Erro Médio Absoluto), as quais indicam que o modelo ARIMA apresentou maior acurácia para ambas as séries analisadas.

Palavras-chave: planejamento de produção; produção de laticínios; modelagem de séries temporais.

1 Universidade Tecnológica Federal do Paraná, *Campus* Medianeira, Av. Brasil, 4232, Independência, 85884-000, Medianeira, PR, Brasil. E-mail: hickmann@utfpr.edu.br

* Autor para correspondência.

Recebido / Received: 17/06/2020
Aprovado / Approved: 18/12/2020

ABSTRACT

Milk production is constantly growing, as it moves the economy and is a source of income for several families. Effective planning of activities performed by both milk and dairy producers is directly related to expectations regarding the annual production of milk. The estimation of milk production can be performed using numerical-statistical forecasting models, with the help of software such as R. Thus, this article addresses a comparative analysis of the forecast of industrialized milk production in Brazil, using ARIMA (Autoregressive Integrated Moving Average) and ETS (Error, Trend, Seasonal) models. The determination of model's parameters and other statistical calculations were performed using free software R for monthly and quarterly data series on milk production, obtained from the IBGE website, from 2004 to 2018. The models provided forecasts for the year 2019 and these were compared with actual values. The metrics used were MAPE (Mean Absolute Percentage Error), RMSE (Root Mean Square Error), and MAE (Mean Absolute Error), which indicate that the ARIMA model presented greater accuracy for both analyzed series.

Keywords: production planning; dairy production; time series modeling.

INTRODUÇÃO

Em 2018 a produção total de leite no Brasil cresceu 1,6% em relação ao ano anterior, com as regiões sul e sudeste respondendo por 68% da oferta nacional, estimada em 33,8 bilhões de litros. Em relação a 2017, o número de vacas recuou 2,9%, enquanto a produtividade subiu 4,7%, chegando a 2.068 litros anuais por animal. Apesar de a produtividade brasileira continuar em patamar ainda relativamente baixo, houve um aumento importante desse indicador (CANAL RURAL, 2020).

De acordo com dados do USDA (*United States Department of Agriculture*) de 2018, a produção mundial de leite avançou de 478,75 milhões de toneladas em 2014 para 498,28 milhões de toneladas em 2017, com previsão de 505,20 milhões de toneladas para 2018 e 513,22 milhões de toneladas para 2019, evidenciando o aumento da produção mundial de leite (FORMIGONI, 2019).

Esse aumento expressivo da produção do leite torna o gerenciamento do setor mais complexo e com uma maior demanda por informações, sendo a previsão da produção leiteira, uma dessas informações que podem contribuir com a tomada de decisão nessa área. Diante desse aumento expressivo, foram desenvolvidas pesquisas sobre métodos de previsão para estimar a produção de leite no Brasil nos próximos anos. É valido ressaltar a importância de um bom planejamento a fim de levar a estabilidade do preço pago ao produtor e assim, reduzir o risco de crises no setor. Além disso, uma boa preparação ajuda a evitar perdas por excesso ou falta de leite para processamento, o que ocasiona a queda do preço do leite pago ao produtor, e por consequência o desperdício.

O uso de técnicas de previsão nas organizações tem sido um tema de interesse na literatura, sendo estudada em relação à sua aplicação real, ao setor da indústria, ao tamanho das organizações, perspectiva de tempo e nível de acurácia (EHLERS, 2007).

Considerando dados mensais e trimestrais da produção de leite cru, resfriado ou não, relativos a todo o Brasil no período de 2004 a 2019, o objetivo deste artigo foi realizar a comparação entre os métodos

estatísticos de previsão ETS (erro, tendência e sazonalidade) e a modelagem ARIMA (modelo autorregressivo de médias móveis) por meio de simulações computacionais utilizando o *software* R (R CORE TEAM, 2019).

Estes modelos de previsão são de prática e rápida aplicação e aliados ao uso de *softwares* de livre acesso, como o programa R que possui pacotes prontos para o uso, permitem a realização de previsões envolvendo ampla quantidade de dados e consequentes inferências acerca dos resultados. A fim de facilitar e o entendimento das modelagens aplicadas foram abordados e comentados os principais tópicos sobre os temas envolvidos, assim como os dados utilizados e seus respectivos resultados.

Séries temporais

Uma série temporal é a representação de valores quantitativos seguindo uma ordem progressiva no tempo. Para estudar séries temporais é importante entender sobre processos estocásticos, o qual é uma coleção de variáveis aleatórias que, em geral, são utilizadas para estudar a evolução de fenômenos que são observados ao longo do tempo (EHLERS, 2007).

A variável é observada em pontos temporais discretos, usualmente equidistantes, e a análise de tal comportamento temporal envolve a descrição do processo ou fenômeno que gera a sequência, sendo assim uma descrição do passado. Um procedimento lógico para realizar previsões é fazer uso desses dados históricos (NOGUEIRA, 2011).

Modelagem ETS

Os modelos ETS são métodos de série temporal em que ETS significa *error*, *trend*, *seasonal*, ou seja, erro, tendência e sazonalidade. O erro pode ser multiplicativo (M) ou aditivo (A), a tendência pode não ter (N), ser multiplicativa (M), multiplicativa amortecida (Md), aditiva (A) ou aditiva amortecida (Ad) e a sazonalidade pode não ocorrer (N), ser multiplicativa (M) ou aditiva (A). Equações do modelo ETS com erros aditivos e multiplicativos podem ser encontrados em Hyndman *et al*. (2008).

Nas equações do modelo ETS com erros multiplicativos e aditivos, as constantes α, γ e β, as quais têm valores iniciais iguais a 0,1, devem ser estimadas de modo a minimizar os erros. Os parâmetros de suavização α, γ e β para cada componente da série são comumente designados no intervalo (0,1) e podem ser estimados minimizando-se a soma dos quadrados dos erros de previsão. Estes parâmetros não dependem da escala das observações, porém das propriedades temporais do nível, tendência e sazonalidade da série (SOUSA, 2011).

De acordo com Miranda (2009), aplicar uma metodologia para escolher o "melhor" modelo em uma classe de modelos é tão importante quanto o processo de estimar os parâmetros de tal modelo. Uma metodologia bastante aceita é o critério Akaike (AIC) (1), onde ρ é o número de parâmetros estimados do modelo e $\theta = (\alpha, \beta, \gamma, \phi)$.

$$AIC = L * (\theta, x_0)\, 2\rho \qquad (1)$$

O modelo que apresentar o menor AIC é escolhido como mais adequado (HYNDMAN *et al*, 2008).

Modelagem ARIMA

O modelo ARIMA foi desenvolvido nos anos 1970 por George Box e Gwilym Jenkins na tentativa de descrever as mudanças na série temporal, utilizando uma abordagem matemática. O modelo se baseia no ajuste dos valores observados, visando reduzir para próximo de zero a diferença dos valores

produzidos no modelo e os valores observados (BOX; JENKINS, 1976; SATO, 2013). Segundo Gomes (2001) para a construção dos modelos ARIMA, Box-Jenkins sugeriram as seguintes etapas iterativas, ilustradas na Figura 1.

Sendo assim, de acordo com Bayer; Souza (2010) o modelo ARIMA (p, d, q) consiste na junção de um modelo autorregressivo (AR) de ordem "p" em uma série diferenciada "d" vezes (número de diferenças necessárias para tornar a série estacionária) e um modelo de média móvel (MA) de ordem "q". Tendo assim, a seguinte forma:

$$\phi\,(B)\,(1 - B)^{d} Z_t = \theta\,(B)\,\varepsilon_t \qquad (2)$$

onde ε_t é ruído branco, $\phi\,(B)$ e $\theta\,(B)$ são o polinômio autorregressivo e polinômio de médias móveis, respectivamente.

O modelo ARIMA sazonal ou SARIMA segue o seguinte modo de apresentação ARIMA $(p, d, q)\,(P, D, Q)$, onde os parâmetros (P, D, Q) são os equivalentes sazonais de (p, d, q). A parte sazonal é representada através de mais três parâmetros semelhantes, sendo assim chamada de SARIMA. Segundo Lopo *et al*. (2012) o modelo SARIMA é definido por uma parte simples de parâmetros (p, d, q) e sazonal composta de parâmetros (P, D, Q).

Desta forma, segundo Espinosa *et al*. (2010), o SARIMA pode ser expresso pela Equação 3.

$$\varphi\,(B)\,\phi\,(B^s)\,(1 - B^s)^{D}\,(1 - B^s)^{d} Z_t = \theta\,(B)\,\theta\,(B^s)\,a_r \qquad (3)$$

Em que:

B = Operador de translação para o passado

$\varphi\,(B)$ = Parte autorregressiva não sazonal ou estacionária de ordem p

$\phi\,(B^s)$ = Parte autorregressiva sazonal de ordem P, e ordem sazonal s

$(1 - B^s)^{D}$ = Parte de integração sazonal de ordem D e estação sazonal s

$(1 - B^s)^{d}$ = Parte de integração não sazonal de ordem d

$\theta\,(B)$ = Parte não sazonal de médias móveis de ordem q

$\theta\,(B^s)$ = Parte sazonal de médias de ordem Q e estação sazonal de ordem s

Testes estatísticos

Para verificação de uma série temporal são realizados testes estatísticos como, por exemplo, teste de Anderson Darling o qual verifica a distribuição normal ou não da série, teste de auto correlação para verificar a estacionariedade e a análise residual. Uma série temporal é estacionária quando suas características estatísticas (média, variância, autocorrelação) são constantes ao longo do tempo (FEIJÓ, 2014).

Intervalos de confiança

O Intervalo de Confiança, introduzido pelo matemático e estatístico Jerzy Neyman, é um dos conceitos mais importantes na estatística por ser utilizado como uma medida de incerteza frente a um cálculo efetuado O intervalo de confiança de 95% é o mais

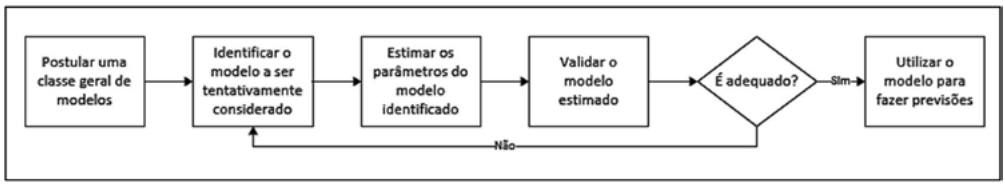

Figura 1 – Etapas iterativas da construção de modelos de previsão

comum dos intervalos relatados na literatura, entretanto podem ser vistos, comumente, níveis de confiança de 80%, 90% e 99%, os quais variam de acordo com o tamanho da amostra estudada, seu nível de confiança e sua variabilidade (GOUVEIA; SOUSA, 2019).

Sofware R

O *software* R é uma linguagem de programação orientada a objetos criada em 1996 por Ross Ihaka e Robert Gentleman que, aliada a um ambiente integrado, permite a manipulação de dados, realização de cálculos e geração de gráficos (SOUZA *et al*., 2010).

Este *software* vem se disseminando pelo fato de ser de código aberto, livre, gratuito e ser adaptável às necessidades do usuário, além de permitir a criação de pacotes. O R Studio é um ambiente que tem por base o programa R, o qual apresenta uma interface mais amigável ao usuário com janelas para plotagem de gráficos e histórico de comandos. Uma vantagem do seu uso são os pacotes que vêm inclusos e os pacotes já desenvolvidos, que podem ser facilmente instalados e carregados na execução do código, permitindo ao usuário a execução de diversas funções e modelos (RITTER; THEY, 2019).

Além disso, é possível realizar a escolha de modelos de forma automática fazendo com que o código investigue qual o modelo é o mais adequado aos dados estudados a partir de um número finito de modelos e critério fixado. Isso permite além de encontrar com facilidade o modelo mais adequado, garantir a maior acurácia, ou seja, diminui drasticamente os níveis de erros e intervalos de precisão.

Pacote *forecast*

Segundo Hyndman *et al*. (2020) o pacote *forecast* é constituído de métodos e ferramentas que permitem exibir e analisar as previsões de séries temporais univariadas, bem como suavização exponencial por meio de modelos de espaço de estados.

Quando é feita a previsão com um modelo ARIMA sem regressores, ou seja, sem dados passados, o pacote *forecast* simplesmente usa os valores passados de sua série histórica para prever valores futuros de forma automática. Nesse caso é possível especificar o horizonte "h", que limita os períodos de previsão (ROCHA, 2018). O pacote permite efetuar previsões e o cálculo das principais medidas dos erros de previsão. Para complementar é feita a análise dos resíduos do modelo e plotados dois gráficos, sendo o primeiro da série original com as previsões, e o segundo da série original com as previsões (HENNING; MIRANDA, 2017).

Já para previsão utilizando modelagem ETS, o pacote *forecast* permite escolher o modelo de suavização exponencial os dados são moldados mais satisfatoriamente. O comando realiza automaticamente um processo de minimização não linear do critério de informação adotado, calculando os parâmetros que serão utilizados nas equações de previsão (CORDEIRO JÚNIOR, 2007).

MATERIAL E MÉTODOS

Visando a comparação entre a modelagem ARIMA e ETS foram utilizados os dados relativos à quantidade de leite cru, resfriado ou não, no Brasil no período de 2004 a 2019, onde estes foram analisados de forma mensal e trimestral. Tais dados foram obtidos no site do IBGE (2020).

A Figura 2 apresenta a série trimestral. Ressalta-se que do primeiro trimestre de 2004 ao último de 2018 os dados foram utilizados para obtenção dos modelos e os dados trimestrais de 2019 foram utilizados somente para verificação da eficiência dos modelos selecionados.

Na Figura 3 tem-se os dados mensais de leite cru ou resfriado no Brasil os quais, da

mesma forma que os dados trimestrais, foram utilizados os dados referentes a 2004 até 2018 para obtenção dos modelos de previsão e os dados de 2019 para verificação.

A Tabela 1 apresenta as principais estatísticas básicas: média, mediana, desvio padrão e coeficiente de variação, tanto dos dados mensais como trimestrais para o período de 2004 a 2018, as quais representam uma breve análise sobre os dados a serem modelados.

Tabela 1 – Parâmetros estatísticos dos dados utilizados no estudo

Parâmetros estatísticos	Trimestral	Mensal
Média	5.292.470	1.761.476
Mediana	5.478.557	1.786.586
Desvio padrão	888.320,4	299.333,2
Coeficiente de variação	16,78%	17,0%

Todos os dados foram organizados e as

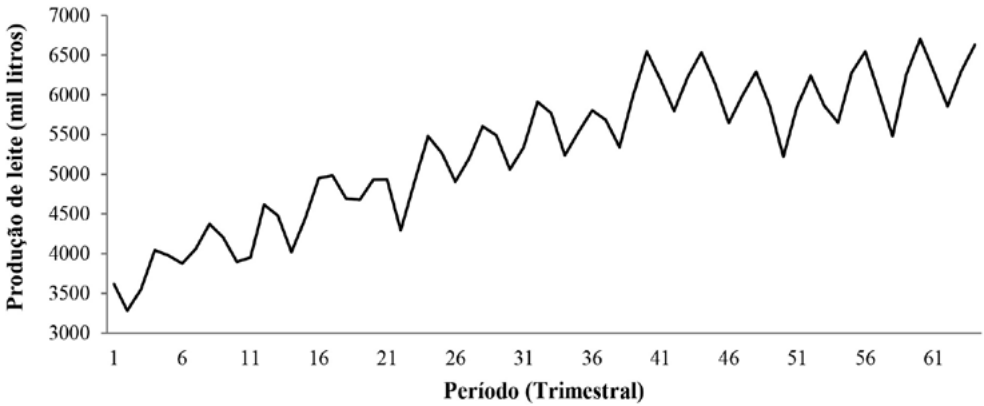

Figura 2 – Quantidade de leite cru ou resfriado produzido no Brasil por trimestre entre 2004 e 2018

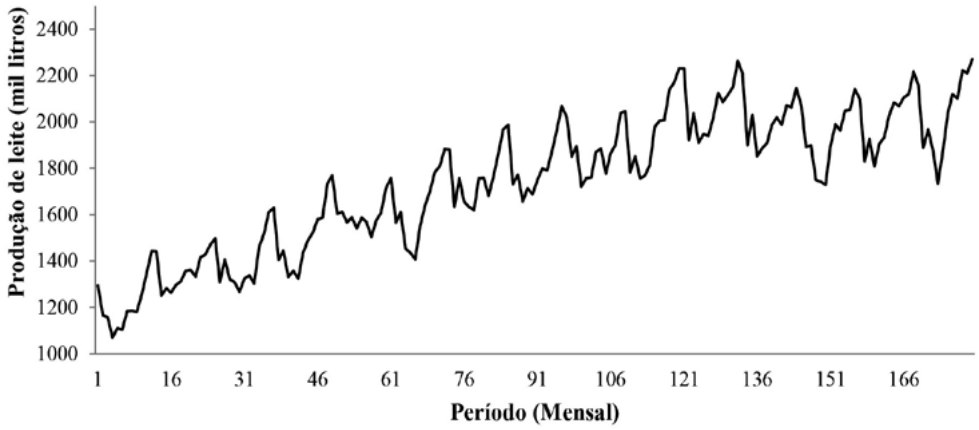

Figura 3 – Quantidade de leite cru ou resfriado produzido no Brasil por mês entre 2004 e 2018

modelagens realizadas com uso do programa R *Studio* e o pacote *forecast*. O ano de 2019 foi utilizado para comparação com os valores da previsão, a qual foi realizada multi-passos à frente, ou seja, o horizonte de previsão é o número de valores futuros que se deseja prever a partir da série de valores passados.

A modelagem utilizando o pacote *forecast* fornece a opção de escolha automática dos modelos. Para obtenção do modelo que melhor se adequa aos dados tanto mensais quanto trimestral foi utilizado o comando *auto.arima* que usa uma variação do algoritmo Hyndman-Khandakar (HYNDMAN; KHANDAKAR, 2008), que combina testes de raiz unitária, minimização do AICc e MLE para obter um modelo ARIMA.

Já para obtenção automática do modelo de suavização exponencial foi usado o comando *ets ()* função em R que estima os parâmetros do modelo e retorna informações sobre o modelo ajustado. Por padrão, ele usa o AICc para selecionar um modelo apropriado, embora outros critérios de informação possam ser selecionados (HYNDMAN; KHANDAKAR, 2008).

A Figura 4 descreve as etapas desenvolvidas para obtenção dos resultados.

RESULTADOS E DISCUSSÃO

A partir dos modelos abordados na fundamentação teórica e aplicando a metodologia citada no tópico anterior, foi realizada a análise computacional utilizando o *software* R, o qual obtém o modelo de forma automática.

Para os dados trimestrais, chegou-se a um modelo ARIMA Multiplicativo o qual é descrito da seguinte forma: ARIMA (0, 1, 0) (0, 1, 2)[4], com sazonalidade trimestral. Posteriormente foi realizado o teste de autocorrelação onde se obteve o P-valor = 0,8931 o que representa que a série de resíduos obtida após o ajuste rejeita a hipótese nula, logo é estacionária. Além disso, aplicou-se também o teste de normalidade de Anderson

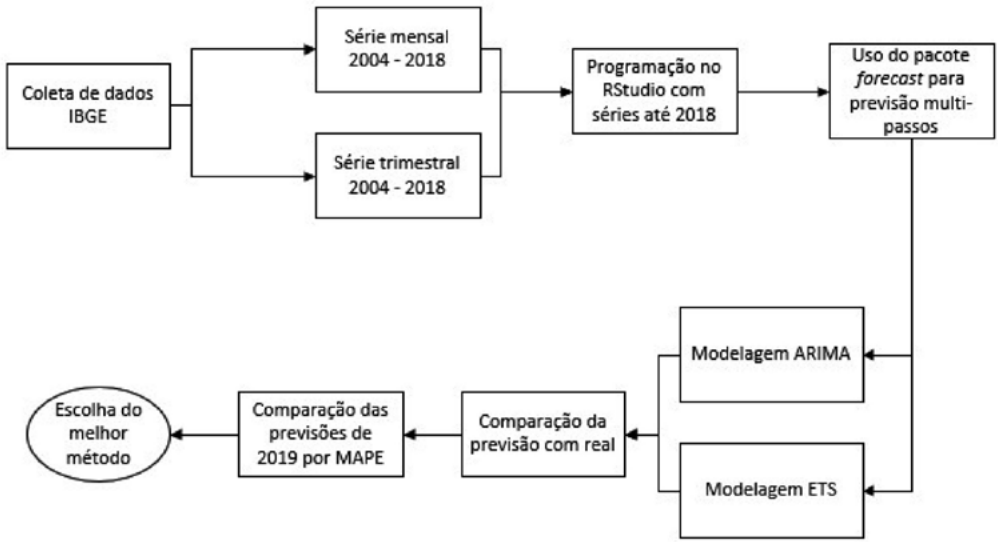

Figura 4 – Fluxograma da metodologia usada para a seleção do método de previsão com melhor ajuste.

Darling, o qual mostra o P-valor = 0,5408 o que representa uma distribuição normal. Pode-se observar na Figura 5 a relação entre os valores reais e os previstos. Também foi realizada a análise residual dos dados, Figura 6, a qual demostra o teste estatístico dos resíduos realizado e seu gráfico que indica aleatoriedade, a função de autocorrelação parcial, além de uma distribuição normal.

Diante das análises e verificação dos

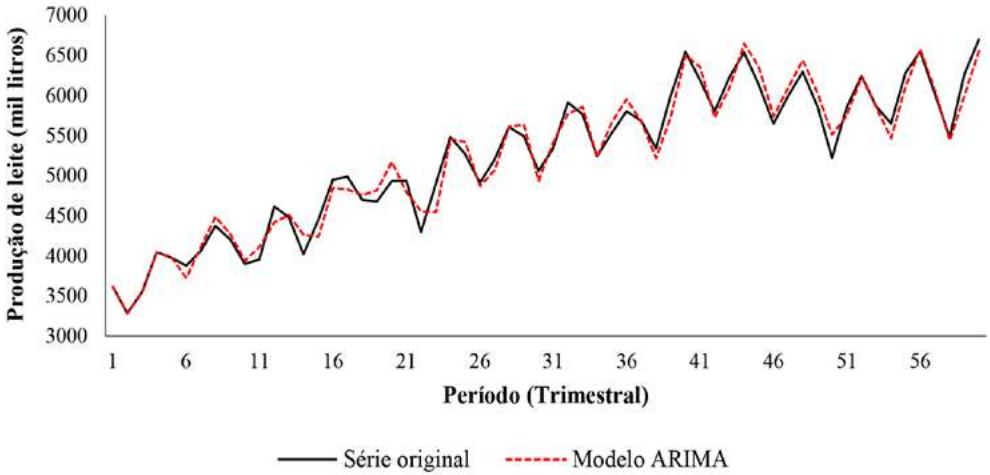

Figura 5 – Série original e prevista dos dados de produção de leite trimestral usando modelo modelagem ARIMA

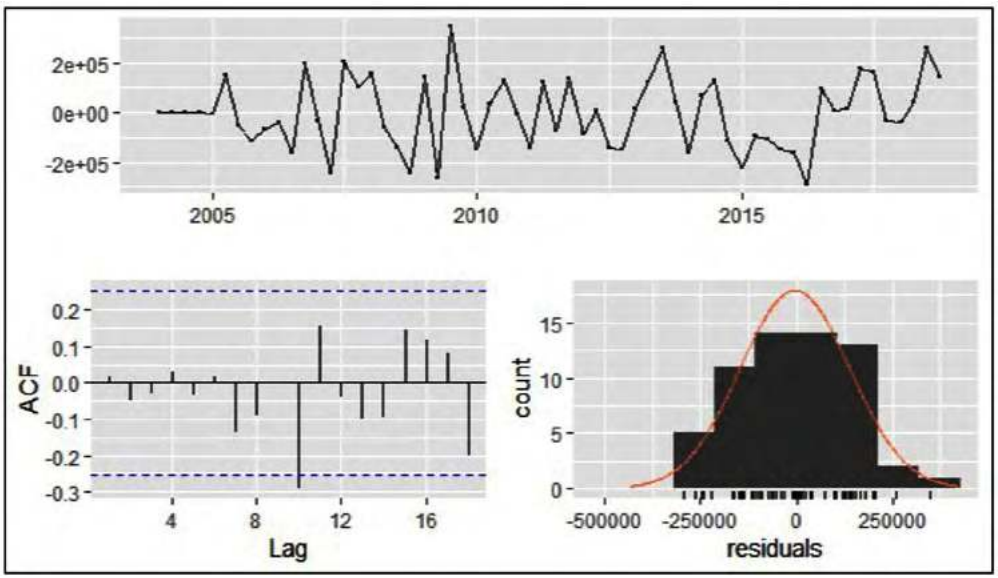

Figura 6 – Análise residual de leite cru ou resfriado produzido no Brasil por trimestre entre 2004 e 2018 do modelo ARIMA

dados foi possível realizar a previsão usando os modelos obtidos, a qual pode ser observada na Figura 7. Neste gráfico tem-se a previsão do modelo para o ano de 2019 bem como o intervalo de confiança, o qual segue o padrão da série temporal.

Posteriormente foi aplicada a modelagem ETS, onde o modelo que apresentou o melhor ajuste foi o modelo ETS (*M*, *Ad*, *M*), que possui erros multiplicativos, tendência aditiva amortecida e sazonalidade multiplicativa. A Tabela 2 apresenta os parâmetros de saída obtidos por meio da aplicação dos dados trimestrais na respectiva modelagem.

A relação entre a série original e a modelada está representada na Figura 8, além disso a previsão do modelo encontra-se representada na Figura 9.

Logo, têm-se os valores previstos e seus respectivos erros, MAE (erro absoluto médio), RMSE (raiz do erro médio quadrático) e MAPE (erro percentual absoluto médio), para o ano de 2019 da série trimestral, os quais estão representados na Tabela 3. Para todas as previsões foram utilizados intervalos de

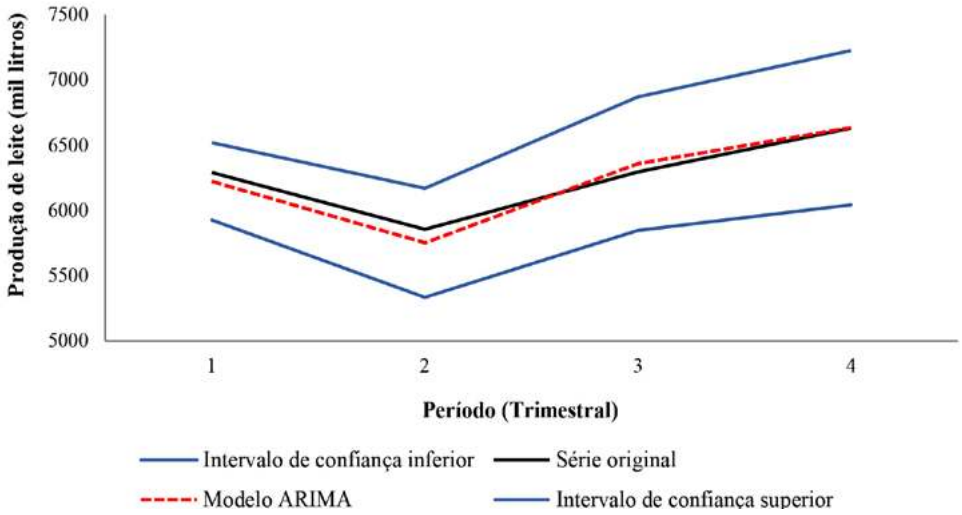

Figura 7 – Produção de leite prevista usando método ARIMA e dados da série trimestral

Tabela 2 – Parâmetros de saída obtidos pela previsão da modelagem ETS dos dados trimestrais

	ETS (*M*, *Ad*, *M*)
Parâmetros de suavização	Alpha = 0,8085 Beta = 1e-04 Gamma = 1e-04 Phi = 0,9788
Estados iniciais	l = 3453273,0487 b = 89635,83994 s = 1,0649 0,9917 0,9279 1,0155 sigma: 0,0338
AIC	1704,002
AICc	1708,492
BIC	1724,946

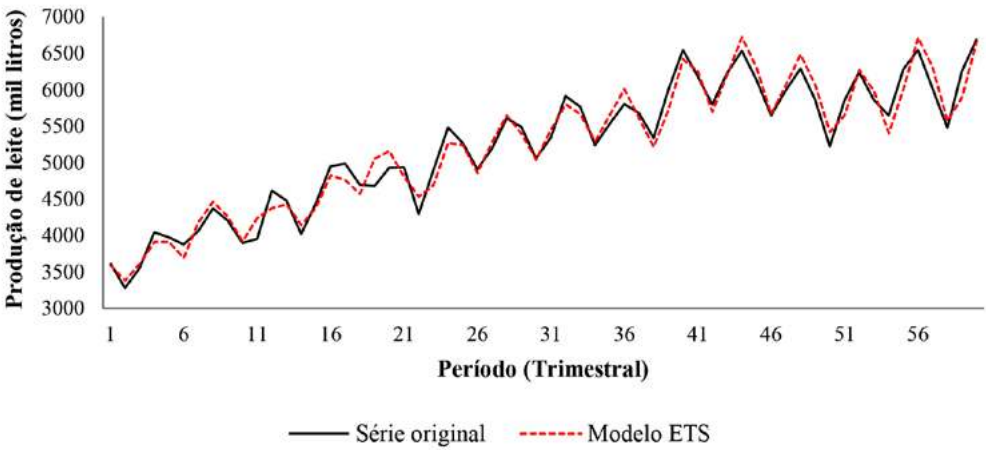

Figura 8 – Série original e prevista dos dados de produção de leite trimestral usando modelo modelagem ETS

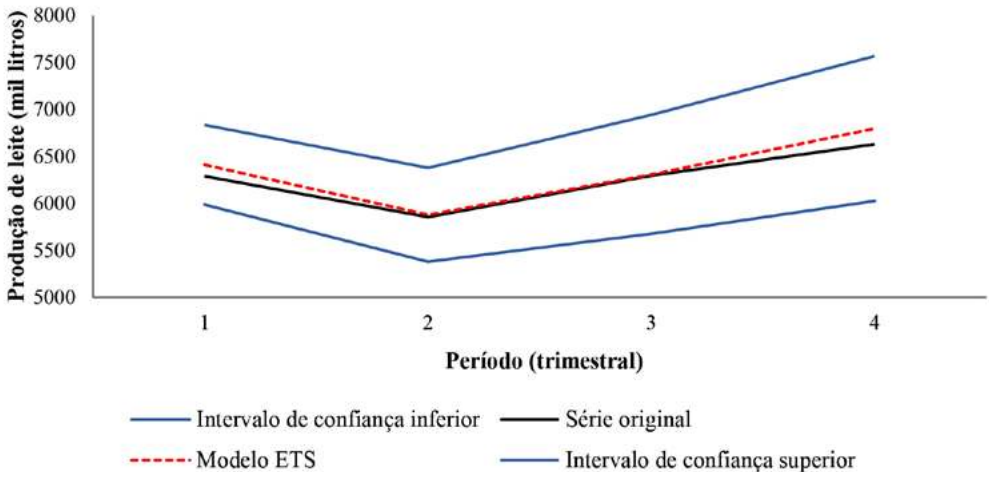

Figura 9 – Produção de leite prevista usando método ETS e dados da série trimestral

confiança com um nível de significância de 95%, observou-se que todos os resultados obtidos ficaram dentro desses limites, bem como os valores reais, garantindo a confiança dos valores.

Aplicando a modelagem ARIMA nos dados mensais estes, assim como os dados trimestrais, também apresentaram estacionariedade, P-valor = 0,3972, e distribuição normal dos dados, P-valor = 0,01044. Sendo assim, a partir da modelagem automática obteve-se o modelo ótimo expresso por ARIMA (1, 1, 1) (0, 1, 2) [12] com sazonalidade anual.

Além disso, na Figura 10 pode-se observar a série original e prevista dos dados, assim como sua análise residual, Figura 11. Pode-se notar que as séries apresentam uma

distribuição normal, ou seja, grande parte das amostras fica em torno de um valor médio, com certa variabilidade.

Para os dados mensais, têm-se os valores da previsão ARIMA para os meses de 2019 representados na Figura 12 onde, assim como as previsões trimestrais e o intervalo de confiança, estão representadas em azul.

O modelo ETS que melhor se ajustou para os dados mensais pode ser expresso como ETS (M, Ad, M), ou seja, assim como para os dados trimestrais o melhor modelo para a previsão mensalmente também é formada por erros multiplicativos, tendência aditiva amortecida e sazonalidade multiplicativa. Seus parâmetros estão representados na Tabela 4.

A série original em comparação com a modelada, Figura 13, mostra o ajuste dos valores logo, é possível prever os dados do ano de 2019 sem dificuldades. Tal previsão esta apresentada, em azul, na Figura 14, bem

Tabela 3 – Produção de leite prevista pelos modelos ARIMA e ETS trimestralmente e seus respectivos erros das previsões

Período (2019)	Real (mil litros)	ARIMA (0,1,0)(0,1,2)[4]	ETS (*M*,*Ad*,*M*)
1º trim.	6.289.978	6.221.523	6.410.437
2º trim.	5.854.269	5.751.613	5.879.716
3º trim.	6.293.943	6.357.204	6.307.760
4º trim.	6.631.070	6.634.096	6.798.207
MAE*		114485,4	135238,4
RMSE*		141793,3	160948,8
MAPE*		2,205812%	2,623655%

* MAE = erro absoluto médio, RMSE = raiz do erro médio quadrático, MAPE = erro percentual absoluto médio.

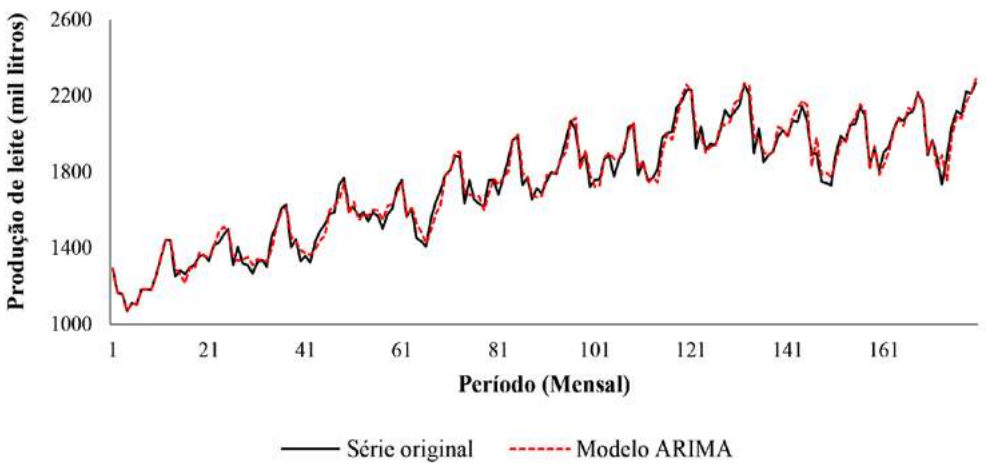

Figura 10 – Série original e prevista dos dados de produção de leite mensal usando modelo modelagem ARIMA

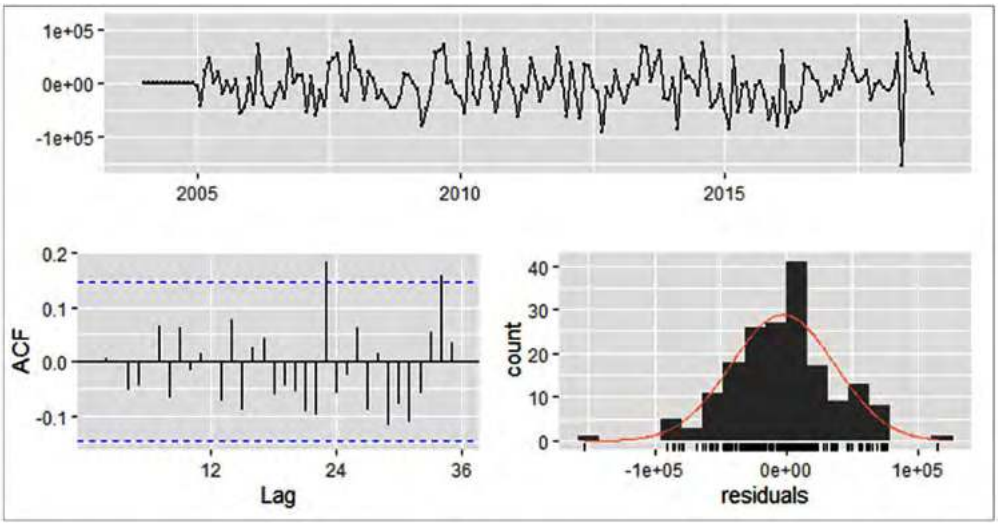

Figura 11 – Análise residual de leite cru ou resfriado produzido no Brasil por mês entre 2004 e 2018 do modelo ARIMA

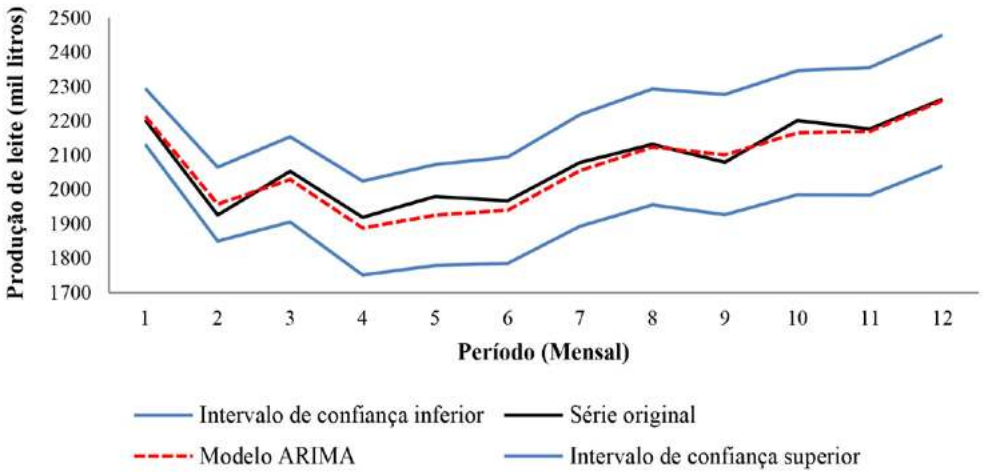

Figura 12 – Produção de leite prevista usando método ARIMA e dados da série

como seu respectivo intervalo de confiança.

Portanto, feitas as análises e previsões, a Tabela 5 traz a comparação entre o valor real obtido em 2019, o valor das modelagens ARIMA e ETS aplicadas, assim como seus respectivos erros. Tais erros reafirmam a viabilidade das previsões por apresentarem números minimamente relevantes, além disso, assim como para a previsão dos dados trimestrais, os mensais também respeitaram os intervalos de confiança estabelecidos, ou seja, todos os resultados ficaram dentro do padrão estabelecidos confirmando a viabilidade das previsões.

Tabela 4 – Parâmetros de saída obtidos pela previsão da modelagem ETS dos dados mensais

	ETS (*M*, *Ad*, *M*)
Parâmetros de suavização	Alpha = 0,9999 Beta = 1e-04 Gamma = 1e-04 Phi = 0,9767
Estados iniciais	l = 1144997,7256 b = 12056,0447 s = 1,0649 0,9917 0,9279 1,0155 s = 1,1053 1,1053 1,0339 0,9844 1,0002 0,9823 0,9279 0,9313 0,9266 0,9936 0,9628 1,0975
AIC	4776,850
AICc	4781,098
BIC	4834,323

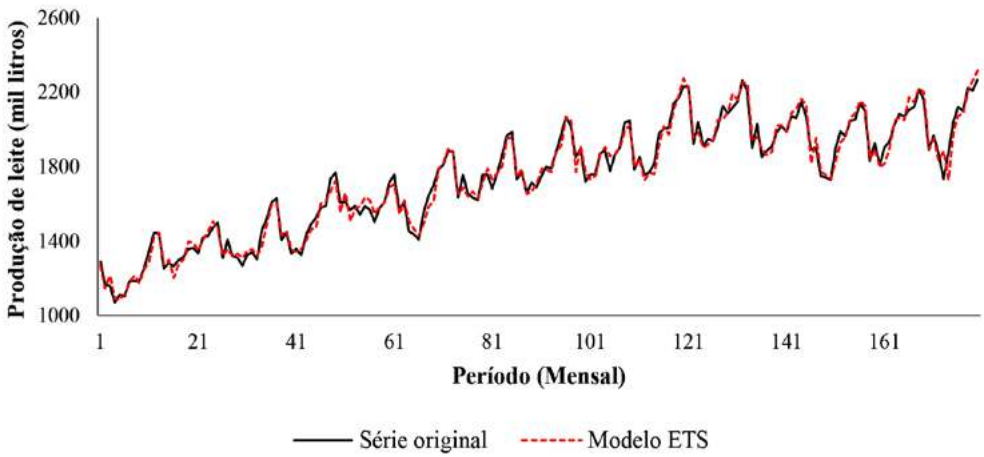

Figura 13 – Série original e prevista dos dados de produção de leite mensal usando modelo modelagem ETS

Diante dos resultados, vale destacar que o método que obteve melhor resultado, para ambos os conjuntos de dados, foi o ARIMA o qual apresentou MAPE de 2,20%, para a previsão trimestral, e 1,71%, para a previsão mensal. Por meio da métrica de erro MAPE é possível observar com facilidade a eficiência dos métodos, pois seus resultados são expressos em porcentagem. Logo, pode-se concluir que a modelagem ARIMA é a mais indicada para as previsões, uma vez que os resultados obtidos se ajustaram melhor aos valores reais e, além disso, os intervalos de confiança se mostram precisos, fornecendo maior credibilidade ao modelo.

CONCLUSÕES

Com o objetivo de comparar métodos estatísticos de previsão a partir de dados de produção de leite no Brasil no período de 2004 a 2019, ambos os modelos ARIMA e ETS apresentam resultados satisfatórios, com o ARIMA levemente superior.

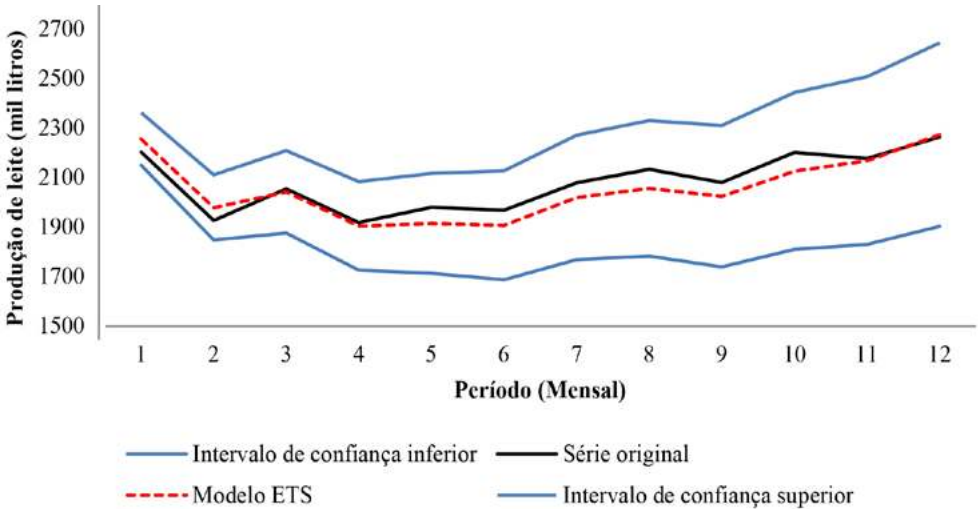

Figura 14 – Produção de leite prevista usando método ETS e dados da série mensal

Tabela 5 – Produção de leite prevista pelos modelos ARIMA e ETS mensalmente e seus respectivos erros das previsões

Período (2019)	Real (mil litros)	ARIMA (1, 1, 1)(0, 1, 2)[12]	ETS (*M*,*Ad*,*M*)
Janeiro	2.213.238	2.213.173	2.254.926
Fevereio	1.936.082	1.957.290	1.978.245
Março	2.064.727	2.029.431	2.041.785
Abril	1.921.613	1.888.043	1.904.160
Maio	1.964.112	1.925.183	1.914.102
Junho	1.969.747	1.939.571	1.907.245
Julho	2.079.962	2.055.242	2.019.217
Agosto	2.133.317	2.124.200	2.056.137
Setembro	2.081.235	2.101.414	2.023.782
Outubro	2.202.276	2.165.305	2.125.667
Novembro	2.178.284	2.169.659	2.167.824
Dezembro	2.265.694	2.259.503	2.272.753
MAE*		29495,3	30702,05
RMSE*		39463,44	38893,53
MAPE*		1,707148%	1,794495%

* MAE = erro absoluto médio, RMSE = raiz do erro médio quadrático, MAPE = erro percentual absoluto médio.

Por fim, modelos como o proposto poderiam ser utilizados na composição de políticas de desenvolvimento regional. Isso evitaria produção excessiva de leite em algumas ocasiões e falta em outras, levando a um equilíbrio entre demanda e oferta que propiciaria o fortalecimento do setor.

REFERÊNCIAS

BAYER, F. M.; SOUZA, A. M. Wavelets e modelos tradicionais de previsão: Um estudo comparativo. **Revista Brasileira de Biometria**, v. 28, n. 2, p. 40-61, 2010.

BOX, G. E. P.; JENKINS, G. M. **Time Series Analysis, Forecasting and Control**. San Franscico: Holden Day, 1976.

CANAL RURAL. **Leite**: Municípios brasileiros atingem padrão europeu de produção. 2020. Disponível em: https://www.canalrural.com.br/noticias/pecuaria/leite/pecuaria-de-leite-espera-crescer-cerca-de-2-em-2020/ Acesso em: 26 mar. 2020.

CORDEIRO JÚNIOR, O. A. **Utilizando séries temporais na previsão da arrecadação do imposto de renda**. 2007. Monografia (Especialização em Orçamento Público) – Instituto Serzedello Corrêa, Centro de Formação, Treinamento e Aperfeiçoamento, Brasília, 2007.

EHLERS, R. S. **Análise de Séries Temporais**. Curitiba: Universidade Federal do Paraná. 2007. Disponível em: http://www.each.usp.br/rvicente/AnaliseDeSeriesTemporais.pdf.

ESPINOSA, M. M.; PRADO, S. M.; GHELLERE, M. Uso do modelo SARIMA na previsão do número de focos de calor para os meses de junho a outubro no Estado de Mato Grosso. **Ciência e Natura**, v. 32, n. 2, p.7-21, 2010. DOI: 10.5902/2179460X9482.

FEIJÓ, C. **Conceitos básicos de séries temporais para modelagem macroeconômica**. Material de apoio à aula de RBC, Curso Macroeconomia Avançada, Universidade Federal Fluminense, 2014. Disponível em: http://www.ppge.uff.br/images/revisão_básica_séries_temporais_material_de_apoio_curso_teoria_macroeconomica_PPGE_UFF.pdf Acesso em: 01 jun. 2020.

FORMIGONI, I. Maiores produtores de leite: Evolução da produção entre 2014 e 2019. **Farmnews**, 2019. Disponível em: http://www.farmnews.com.br/mercado/maiores-produtores-de-leite/Acesso em: 26 mar. 2020.

GOMES, S. T. **Diagnóstico e perspectiva da produção de leite no Brasil**. 2001. Disponível em: https://docplayer.com.br/6316732-Evolucao-recente-e-perspectiva-da-producao-de-leite-no-brasil-1.html Acesso em: 28 abr. 2020.

GOUVEIA, R.; SOUSA, S. **Significado de Intervalo de Confiança**. [2019]. Disponível em: https://www.significados.com.br/intervalo-de-confianca/ Acesso em: 30 abr. 2020.

HENNING, E.; MIRANDA, R. G. Modelo ARIMA com o pacote forecast. **Núcleo de Normatização e Qualimetria da Universidade Federal de Santa Catarina**, 2017. Disponível em: https://docplayer.com.br/39835031-Modelo-arima-com-o-pacote-forecast.html. Acesso em: 13 maio 2020.

HYNDMAN, R. *et al*. **Package 'forecast'**: forecasting functions for time series and linear models. 2020. Disponível em: https://cran.r-project.org/web/packages/forecast/forecast.pdf Acesso em: 12 mar. 2020.

HYNDMAN, R. J. *et al*. **Previsão com**

suavização exponencial: A abordagem do espaço de estados. Berlim: Springer-Verlag, 2008.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: The forecast package for R. **Journal of Statistical Software**, v. 27, n. 3, p. 1-22, 2008 DOI: 10.18637/jss.v027.i03.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Pesquisa trimestral do Leite**. 2020. Disponível em: https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9209-pesquisa-trimestral-do-leite.html?edicao=20754&t=series-historicas Acesso em: 15 abr. 2020.

LOPO, A. B.; SPYRIDES, M. H. C.; LUCIO, P. S. Índice de radiação ultravioleta máximo da cidade de Natal: Modelagem via método univariado SARIMA. *In*: CONGRESSO DE MATEMÁTICA APLICADA E COMPUTACIONAL, 1., 2012, Natal. **Anais** [...]. Natal: UFRN, 2012. p. 414-417.

MIRANDA, R. G. **Espaço admissível para os parâmetros do modelo de suavização exponencial com dupla sazonalidade aditivo**. 2009. Tese (Doutorado em Engenharia de Produção) – Departamento de Engenharia de Produção e Sistemas, Universidade Federal de Santa Catarina, Florianópolis, 2009.

NOGUEIRA, F. **Modelagem e simulação**: modelos de previsão. Notas de Aula. 2011. Disponível em: http://www.ufjf.br/epd042/files/2009/02/previsao1.pdf Acesso em: 13 mar. 2020.

R CORE TEAM. **R**: a language and environment for statistical computing. Vienna: R Foundation for Statistical Computing, 2019. Disponível em: https://www.R-project.org. Acesso em 21 de maio de 2020.

RITTER, M. N.; THEY, N. H. **Introdução ao software estatístico R**. Imbé, RS: Universidade Federal do Rio Grande do Sul, 2019. Disponível em: https://lume.ufrgs.br/bitstream/handle/10183/188778/001087242.pdf?sequence=1&isAllowed=y .Acesso em 13 mar. 2020.

ROCHA, V. **Modelo ARIMA e previsão no R**. Disponível em: https://www.monolitonimbus.com.br/modelo-arima-e-previsao-no-r/ Acesso em: 13 maio 2020.

SATO, R. C. Gerenciamento de doenças utilizando séries temporais com o modelo ARIMA. **Einstein**, v. 11, n. 1, 2013. DOI: 10.1590/S1679-45082013000100024.

SOUSA, A. P. Análise comparativa da previsão de séries temporais através da modelagem HOLT WINTERS e ARIMA para preço do etanol em Goiás. *In*: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 31., 2011, Belo Horizonte. **Anais** [...]. Belo Horizonte: Associação Brasileira de Engenharia de Produção, 2011.

SOUZA, E. F. M.; PETERNELLI, L. A.; MELLO, M. P. **Software Livre R**: aplicação estatística. 2010. Disponível em: http://www2.ufersa.edu.br/portal/view/uploads/setores/137/Apostilas%20e%20Tutoriais%20-%20R%20Project/Apostila%20R%20-%20GenMelhor.pdf Acesso em: 13 mar. 2020.