



ConBRepro

X CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



02 a 04
de dezembro 2020

Previsão para o número de Óbitos por Covid-19 no Brasil utilizando o modelo ARIMA

Victor Bueno Fontes

Universidade Tecnológica Federal do Paraná

Resumo: O mundo está passando pelo possível maior desafio sanitário do século, causado pelo vírus SARS-CoV-2 e a doença que ele causa, Covid-19. Neste momento há a necessidade de tomada decisões e definições das estratégias para o enfrentamento desta doença. Tendo em consideração o contexto brasileiro de desigualdade social e de acesso à saúde, que aumenta a complexidade acerca da tomada de decisões, que necessitam buscar poupar vidas, garantindo a assistência de boa qualidade ao paciente grave e, também, minimizar os danos econômicos, sociais e psicológicos das populações mais vulneráveis, por meio da adoção de medidas fiscais e sociais (Apuzzo, 2020), é conclusivo a necessidade de ferramentas que auxiliem nesta tarefa, sendo a predição de situações futuras do contexto pandêmico uma possível aliada. Dessa forma, de maneira quantitativa, buscou-se prever os óbitos decorrentes do SARS-CoV-2, utilizando a metodologia ARIMA e programação em R para esta finalidade.

Palavras-chave: ARIMA, Previsão, Covid-19, SARS-CoV-2.

Forecasting for the number of deaths by Covid-19 in Brazil using the ARIMA Model

Abstract: The world is experiencing the possible greatest health challenge of the century, caused by the SARS-CoV-2 virus and the disease it causes, Covid-19. At this moment, there is a need to make decisions and define the strategies that will have to be taken to face this disease. Considering the Brazilian context of social inequality and access to health, it increases the complexity of making decisions that need to seek to save lives, ensuring good quality care for critically ill patients and also minimizing economic, social, and psychological damage of the most vulnerable populations, through the adoption of fiscal and social measures (Apuzzo, 2020). The need for tools to assist in this task is conclusive, and the prediction of future situations in the pandemic context is a possible ally. Thus, quantitatively, we sought to predict deaths arising from SARS-CoV-2, using the ARIMA methodology and R programming for this purpose.

Keywords: ARIMA, Forecast, Covid-19, SARS-CoV-2.

1. Introdução

O SARS-CoV-2, juntamente com a doença que causa, tem se apresentado como um dos maiores desafios sanitários deste século. No mês de Setembro, poucos meses depois do

início da pandemia na China, há mais de 32 milhões de casos de COVID-19. No Brasil, até então, já foram registrados mais de 4 milhões de casos pela doença.

As decisões acerca das estratégias a serem utilizadas no enfrentamento da pandemia são incertas, tendo em vista o insuficiente conhecimento científico sobre o novo coronavírus. No Brasil, o desafio é maior por conta do contexto de desigualdade social e de acesso a saúde, de acordo com a Pesquisa Nacional de Saúde, realizada em 2013, entre os 20% mais pobres da população, 94,4% não possuem plano de saúde e 10,9% se auto avaliam com saúde regular, ruim ou muito ruim, mas não consultaram um médico no último ano.

Tendo em consideração a complexidade acerca da tomada dessas decisões, que necessitam buscar poupar vidas, garantindo a assistência de boa qualidade ao paciente grave e, também, minimizar os danos econômicos, sociais e psicológicos das populações mais vulneráveis, por meio da adoção de medidas fiscais e sociais (Apuzzo, 2020). É concludente a necessidade de ferramentas que auxiliem nesta tarefa, sendo a predição de situações futuras do contexto pandêmico uma possível aliada.

Os modelos Autorregressivo Integrado de Média Móvel (ARIMA), propostos pela metodologia Box-Jenkins, possuem como objetivo a realização de previsão (FAVA, 2000). É uma das metodologias de estudo e previsão de Séries Temporais mais difundidas e possui aplicação em áreas como a médica, ambiental, financeira, na engenharia e previsão da qualidade do ar (WERNER; RIBEIRO, 2003).

Dessa forma, de maneira quantitativa, buscou-se prever os óbitos decorrentes diretamente do SARS-CoV-2, utilizando a metodologia ARIMA e programação em R para essa tarefa.

2. Referencial Teórico

2.1 Covid-19

Com mais de 32 milhões de casos no mundo, em Setembro de 2020, de acordo com a Organização Mundial da Saúde (OMS), a doença respiratória COVID-19, causada pelo vírus SARSCoV-2 surgiu na China em dezembro de 2019. Sua circulação foi confirmada em 9 de janeiro de 2020. Desde então, a doença se propagou intensamente pelo mundo (LANA et al., 2020) desencadeando uma pandemia global (Chan et al., 2020).

A doença se espalha, principalmente, pelo trato respiratório, por gotículas, secreções respiratórias e contato direto (Guo YR et al, 2020). A maioria dos pacientes apresentam bom prognóstico, enquanto alguns pacientes entram em estado crítico, especialmente aqueles do grupo de risco, como idosos e aqueles com doença crônica subjacente (Guo YR et al., 2020). Entre os sintomas estão, febre, mal-estar, tosse e embora o sinal clínico inicial da Covid-19, que permitiu sua detecção, tenha sido a pneumonia, há relatos mais recentes de sintomas gastrointestinais e infecções assintomáticas, principalmente em crianças (Chan JFW et al, 2020).

Um dos problemas graves da COVID-19 é seu período de incubação de até 14 dias, assim, durante este período o vírus pode ser transmitido (Farida et al., 2020). A disseminação deste patógeno é muito perigosa e requer a construção de políticas públicas, além de planos mais rígidos de enfrentamento e contingência (Farida et al., 2020 e Fernandes et al., 2020).

Segundo a OMS, ao apresentar os sintomas, é necessário descansar, dormir, manter o corpo aquecido, beber bastante líquido, usar um umidificador de ar ou tomar banho quente para aliviar a tosse e a dor de garganta. Estas recomendações somadas a inexistência de medicamento específico para tratar ou prevenir o novo Coronavírus são fatores preocupantes, que unidos a desigualdade ao acesso da saúde no Brasil, se tornam críticos, tendo em vista que, de acordo com dados da Pesquisa Nacional de Saúde, de 2013, entre

os 20% mais pobres da população, 94,4% não possuem plano de saúde e 10,9% se auto avaliam com saúde regular, ruim ou muito ruim, mas não consultaram um médico no último ano. Como um agravante, o número de leitos de Unidade de Tratamento Intensivo (UTI) disponíveis, para os usuários do Sistema Único de Saúde, de apenas 1,04 leito por 10 mil habitantes.

2.2 Série temporal

Uma Série Temporal, também denominada Série Histórica, é uma sequência de dados obtidos em intervalos regulares de tempo durante um período específico (Morettin e Toloí, 1987), ou seja, é uma coleção de observações feitas sequencialmente ao longo do tempo (Ehlers,2009), tendo como uma de suas características fundamentais a relevância da ordem dos dados. Na maioria das situações, uma Série Temporal estará em função do tempo, mas em outras situações pode ser uma função de outro parâmetro físico, como o espaço.

Segundo Costa (2009), são diversos os exemplos de Séries Temporais (ST) em nossa realidade cotidiana, tendo aplicações em várias ciências como economia, medicina, meteorologia, epidemiologia, astronomia, física, engenharias entre outras. São exemplos deste tipo de sequência de dados:

- a) Taxas de desemprego mensais de um determinado local;
- b) Produção diária em uma fábrica;
- c) População em cada década de um estado;
- d) Preço diário de uma ação;

Em relação a coleta de dados. Uma ST é classificada como contínua quando as observações são realizadas continuamente no tempo e discreta quando as observações são realizadas em tempos específicos, geralmente equiespaçados.

De acordo com Morettin e Toloí(2006) alguns conceitos importantes no entendimento de séries temporais são os Processos Estocásticos, Tendência, Sazonalidade e Estacionariedade, descritos a seguir:

i)Processos Estocásticos: É uma coleção de variáveis aleatórias que, em geral, são utilizadas para estudar a evolução de fenômenos que são observados ao longo do tempo.

ii)Tendência: Comportamento de longo prazo da série, que pode ser causada por qualquer aspecto que afete a variável de interesse no longo prazo.

iii)Sazonalidade:Existente quando os fenômenos que ocorrem durante o tempo se repete a cada período idêntico de tempo, como flutuações periódicas. A sazonalidade pode ser determinística, quando seu padrão sazonal é regular e estável no tempo, ou estocástica, quando a componente sazonal da série varia com o tempo.

iv)Estacionariedade: Relativa ao comportamento de uma ST em relação a sua média, variância e estrutura de autocorrelação, sendo estacionária quando apresenta equilíbrio estatístico sem tendência e não estacionária quando suas propriedades mudam com o decorrer do tempo. (MORETTIN e TOLOI 2006):

O objetivo de uma analisar uma série temporal são diversos. Podendo esta análise ser utilizada para descrever propriedades da série, por exemplo, o padrão de tendência, existência de variação sazonal, outliers, alterações estruturais, controlar processos, prever valores futuros com base em valores passados, entre outros.

O interesse deste exemplar está em prever valores futuros com base em valores passados. Isto, considerando que o processo de tomada de decisão é sempre importante porque define rumos para a empresa (e sociedade) tanto no curto, quanto no médio ou longo prazo (RIBEIRO, 2003).

2.3 ARIMA

Os modelos Autorregressivo Integrado de Média Móvel (ARIMA) propostos pela metodologia Box-Jenkins têm como objetivo a realização de previsão (FAVA, 2000). É uma das metodologias de estudo e previsão de Séries Temporais mais difundidas e possui aplicação em áreas como a médica, ambiental, financeira, na engenharia e previsão da qualidade do ar (WERNER; RIBEIRO, 2003).

Uma premissa deste modelo é que a variação contida na série pode ser representada pela combinação de três filtros: autorregressivo (AR), de integração (I) e de médias móveis (MA). Para a modelagem de uma determinada série temporal, tanto se pode utilizar os três, quanto apenas um subconjunto destes (FAVA, 2000). Outra premissa é que os valores de uma série temporal são altamente dependentes dos valores passados, sendo possível explicar cada valor por valores prévios da série (PELLEGRINI, 2000).

Essa metodologia explora a correlação temporal entre os valores da série e por envolverem apenas uma série de tempo, são classificados como modelos univariados (FAVA, 2000), ou seja, utilizam apenas uma variável para sua execução e realizam sua explicação determinando ela por meio de seus valores passados, dos valores passados de choques e dos valores passados dos erros ou resíduos (SARTORIS, 2003; MATOS, 2000).

A forma geral dos modelos é ARIMA(p, d, q), onde os valores de “p” refere-se ao processo autorregressivo não sazonal incorporado no modelo, é a ordem da componente autorregressiva e refere-se a diferença de tempo entre o valor atual e os valores que o predizem, o valor de “d” representa o grau de diferenciação e “q” refere-se ordem de componente da média móvel.

Os modelos ARIMA são utilizados para séries estacionárias, assim como os modelos SARIMA, que consideram uma componente sazonal (BOX et al;). Caso seja trabalhado com uma série não estacionária, será necessário diferenciar a mesma, somente assim será possível utilizar um modelo ARIMA para a série (GUJARATI; PORTER, 2011).

Para realizar a identificação do modelo que deve ser utilizado analisa-se a função de autocorrelação amostral (ACF), dada por:

$$ACF_{(X_t, X_{t+k})} = \sqrt{\frac{COVARIÂNCIA_{(X_t, X_{t+k})}}{VARIÂNCIA_{(X_t)} VARIÂNCIA_{(X_{t+k})}}} \quad (1)$$

Para a análise da autocorrelação utilizamos as seguintes relações:

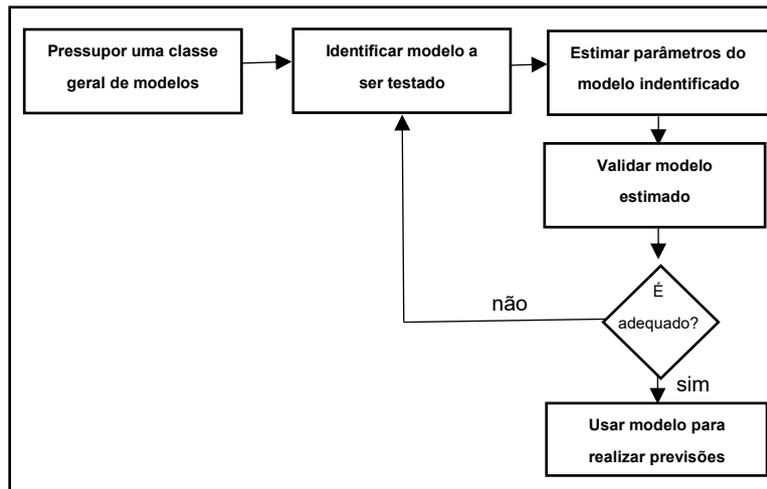
- a) $1 \leq ACF_{(X_t, X_{t+k})} \leq -1$;
- b) $ACF_{(X_t, X_{t+k})} = 1$: relação linear perfeita e positiva;
- c) $ACF_{(X_t, X_{t+k})} = -1$: relação linear perfeita e negativa;
- d) $ACF_{(X_t, X_{t+k})} = 0$: inexistência de relação linear.

Utiliza-se, também, a função de Autocorrelação Amostral Parcial (PACF), que representa a correlação entre duas variáveis X_t e X_{t+k} , eliminando a dependência dos termos intermediários $X_{t-1}, \dots, X_{t-(k+1)}$. É denotado por:

$$PACF_{(X_t, X_{t+k})} = ACF_{(X_t, X_{t+k} | X_{t-1}, \dots, X_{t-(k+1)})} \quad (2)$$

Para facilitar o processo de escolha, do melhor modelo, é possível proceder de acordo com a metodologia iterativa Box-Jenkins, apresentada na Figura 1 a seguir:

Figura 1 – Metodologia Box-Jenkins



Fonte: Adaptado de Box, Jenkins e Reinsel (1994)

Utilizando um conjunto de funções do Software Livre RStudio R Core Team (2020) é possível utilizar o método de previsão automática do ARIMA, onde é selecionado um modelo adequado através da escolha da ordem p,d,q, efetuada através de testes de raiz unitária e o critério de AIC, sendo escolhido a ordem que adotar o menor valor para esse critério. O teste para encontrar o valor de AIC é repetido até que se encontre o menor valor possível entre os modelos testados.

O AIC (Akaike Information Criterion) é um dos principais critérios do conjunto de mecanismos utilizados para encontrar o número ideal de parâmetros de um modelo. Este busca minimizar uma função baseada nos resíduos, penalizando a mesma pelo número de regressores. (BUENO, 2008) e funciona melhor para pequenas amostras, não obstante seja viesado para escolher modelos parametrizados (BUENO, 2008).

2.4 Medidas de Acurácia

Para que seja possível identificar a acurácia e conseqüentemente saber o quão confiável são os modelos de previsão propostos, é necessário averiguar alguns métodos estatísticos de erros. Segundo ,Makridakis e Hibon (1995) existem catorze medidas de precisão que podem ser identificados na literatura existente sobre previsão, de acordo com Fair (1986), existem três medidas mais comuns de precisão preditiva, sendo elas RMSE, MAE e índice de desigualdade de Theil. Neste exemplar utilizaremos RMSE, MAE, MAPE e MASE, desta forma, iremos nos restringir a esses 4 tipos de métodos. Onde serão considerados “n” o número de dados, O o valor observado e P o valor previsto.

O RMSE(Root Mean Squared Error) ou Raiz do Erro Quadrático Médio, representa as diferenças individuais quadráticas entre as séries temporais observadas e previstas:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad (3)$$

Enquanto o RMSE representa as diferenças entre O e P elevadas ao quadrado. A verdadeira média dos desvios pode ser descrita pelo MAE(Mean Absolute Error):

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \quad (4)$$

Além dessas, outra forma de medida de erro é o MAPE(Mean Absolute Percentage Error) ou Média do Erro Absoluto Percentual, que possui representação em termos percentuais.

$$\text{MASE} = \frac{\text{MAE}}{\text{MAE}_{\text{na amostra,naive}}} \quad (5)$$

Se $\text{MASE} > 1$ significa que a previsão atual é menos eficiente fora da amostra que uma previsão do tipo Naive na amostra. Desta forma, caso MASE dê maior que 1, seria interessante mudar o modelo de previsão para um do tipo Naive.

3 Metodología

Para a elaboração deste trabalho foi realizada a coleta de dados da série histórica do número de Mortes de Covid-19 em todo território brasileiro, tendo como fonte o Ministério da Saúde e Secretaria de Vigilância em Saúde (SVS): Guia de Vigilância Epidemiológica do COVID-19. Os dados escolhidos para a realização da análise da série temporal correspondem aos do dia 26/02/2020 até 23/09/2020.

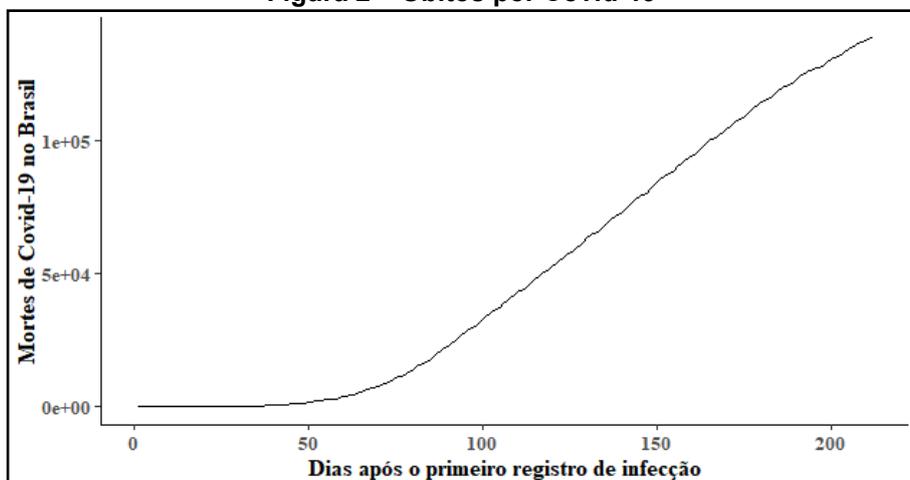
A análise dos dados foi realizada com o auxílio do Software Livre RStudio R Core Team (2020). Os algoritmos e estruturas de modelagem para previsão da série temporal foram provenientes do pacote "Forecast" (HYNDMAN; KHANDAKAR, 2008). Após a realização da predição pelo método automático do ARIMA, utilizando a função "auto.arima", que seleciona o melhor modelo de acordo com o critério do AIC (HYNDMAN e KHANDAKAR, 2008), houve a análise dos resíduos, para verificar a adequação do modelo e também avaliar os erros de previsão dentro e fora da amostra, isto, utilizando os métodos de acurácia MAE (Mean Absolute Error), MAPE (Mean Absolute Percentage Error), RMSE (Root Mean Squared Error) e MASE (Mean Absolute Scaled Error).

A metodologia utilizada para o estudo desses objetos pode ser classificada como quantitativa, sendo esta um procedimento racional e sistemático que tem como objetivo proporcionar respostas aos problemas que são propostos, de acordo com Gil (2007, p. 17), descritiva pois visa descrever as características de determinada população ou fenômeno ou o estabelecimento de relações entre variáveis (Silva & Menezes, 2000).

4. Resultados e discussão

A Figura 2, apresentada a seguir, representa os dados da Série Temporal que descreve os óbitos entre os dias 26/02/2020, data em que houve o registro do primeiro caso de Covid-19 no Brasil, e 23/09/2020, dia em que os dados foram coletados.

Figura 2 – Óbitos por Covid-19



Fonte: Próprio Autor (2020)

Ao utilizar o algoritmo “auto.arima”, é obtido que o modelo mais adequado para realizar a previsão da Série Temporal é o ARIMA (3,2,2). O algoritmo realiza essa decisão utilizando como base o critério de AIC e raiz unitária. Os critérios são representados a seguir:

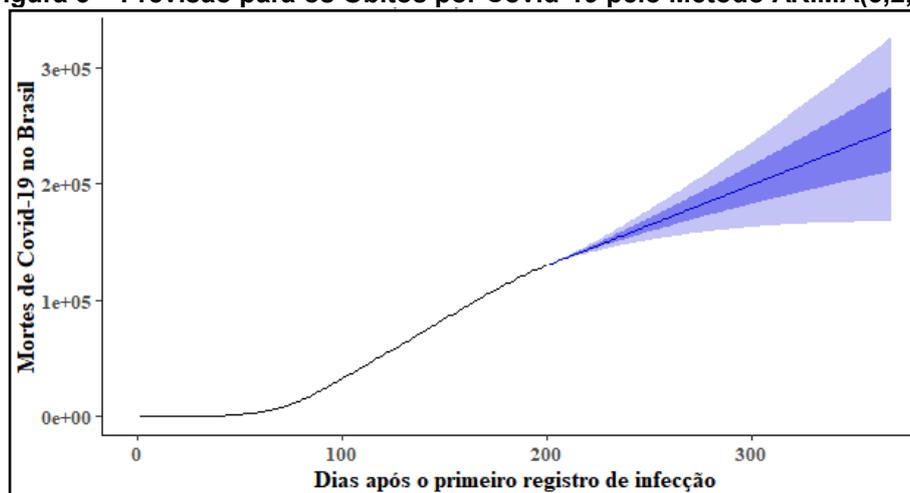
Tabela 1 – Coeficientes

Ar1	Ar2	Ar3	Ma1	Ma2
0.8658	-0.5255	-0.3290	-1.4638	0.9028
0.0693	0.0825	0.0677	0.0299	0.0421
sigma^2	estimated	as 30484:	log likelihood=	-1381.87
AIC=2775.74	AICc=2776.15	BIC=2795.82		

Fonte: Próprio Autor (2020)

Após a definição do melhor modelo, é realizada a previsão, representada pela Figura 3 ,a seguir:

Figura 3 – Previsão para os Óbitos por Covid-19 pelo Método ARIMA(3,2,2)



Fonte: Próprio Autor (2020)

A Tabela 2, apresenta os valores previstos para os três últimos dias do ano de 2020 e os três primeiros dias de 2021. O modelo prevê, caso não haja mudanças de atitudes governamentais e sociais, para o dia 31/12/2020, 30% de probabilidade do número de óbitos estar entre 188022 e 227867 e 60% de se encontrar entre 164430 e 251459.

Tabela 2 – Previsão para os dias entre 29/12/2020 e 03/01/2021

Data	Previsão	Lo 30	Hi 30	Lo 60	Hi 60
29/12/2020	206512	187116	225907	164148	248876
30/12/2020	207243	187585	226901	164306	250181
31/12/2020	207944	188022	227867	164430	251459
01/01/2021	208613	188425	228801	164519	252707
02/01/2021	209271	188817	229726	164594	253948
03/01/2021	209947	189225	230669	164686	255208

Fonte: Próprio Autor (2020)

A Tabela 3, apresenta os valores previstos para um ano após o registro do primeiro caso de infectado no Brasil, ocorrido no dia 26/02/2020. O modelo prevê que, caso não haja mudanças de atitudes governamentais e sociais, no dia 26/02/2021 haverá 30% de probabilidade do número de óbitos estar entre 210827 e 284372 e 60% de se encontrar entre 167281 e 327919.

Tabela 3 – Previsão para o dia 26/02/2021

Data	Previsão	Lo 30	Hi 30	Lo 60	Hi 60
26/02/2021	247600	210827	284372	167281	327919

Fonte: Próprio Autor (2020)

A Tabela 4, apresentada a seguir, representa os valores dos testes de acuracidade do modelo, demonstrando que este possui alta acuracidade e portanto é um modelo com resultados precisos. Independentemente da medida, o objetivo é obter os menores valores possíveis.

Tabela 4 – Medidas de Acurácia

ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
7.966164	167.7166	122.0322	2.116526	2.559764	0.1862358	-0.1492709

Fonte: Próprio Autor (2020)

5. Conclusão

Os métodos de previsão são fundamentais para auxiliar na tomada de decisão, visto que possuem o potencial de fornecer informações sobre casos futuros de óbitos causados pelo Covid-19, possuindo, dessa forma, a capacidade de serem importantes para diversas instituições da sociedade, especialmente para as Instituições Políticas, visto que o entendimento do crescimento de óbitos permite estudos e implantação de políticas públicas para lidar com a pandemia com maior precisão.

Ao realizar a observação das medidas de acurácia, representadas na Tabela 4, é factível concluir que o método de predição ARIMA (3,2,2) é adequado e tende a gerar ótimos resultados.

A Tabela 2 apresenta os valores previstos para os três últimos dias do ano de 2020 e os três primeiros dias de 2021. O modelo prevê que, caso não haja mudanças de atitudes governamentais e sociais, no dia 31/12/2020, haverá 30% de probabilidade do número de óbitos estar entre 188022 e 227867 e 60% de se encontrar entre 164430 e 251459. A Tabela 3, apresenta os valores previstos para um ano após o primeiro registro do primeiro caso de infectado no Brasil, ocorrido no dia 26/02/2020. O modelo prevê que, caso não haja mudanças de atitudes governamentais e sociais, no dia 26/02/2021, haverá 30% de

probabilidade do número de óbitos estar entre 210827 e 284372 e 60% de se encontrar entre 167281 e 327919. Valores impressionante considerando que o modelo prevê óbitos.

6. Referências

Apuzzo M, Pronczuk M. COVID-19's economic pain is universal. But relief? Depends on where you live. The New York Times 2020; 23 mar. <https://www.nytimes.com/2020/03/23/world/europe/coronavirus-economic-relief-wages.html>.

BOX, G. E. P.; JENKINS, G. M. Time series analysis forecasting and control. San Francisco: HoldenDay, 1976. Edição revisada.

BUENO, R.de. L.da.S. Econometria de Séries Temporais. São Paulo, Cengage Learning, 2008.

Chan JFW, Yuan S, Kok KH, et al. A familial cluster of pneumonia associated with the 2019 novel coronavirus indicating person-to-person transmission: a study of a family cluster. Lancet 2020;395(10223):514-523. doi: [https://doi.org/10.1016/S0140-6736\(20\)30154-9](https://doi.org/10.1016/S0140-6736(20)30154-9)

EHLERS, R. S. Análise de Séries Temporais. 4ª ed., Laboratório de Estatística e Geoinformação, Departamento de Estatística, UFPR, Curitiba, PR, 2007. Disponível em: . Acesso em: 20 de agosto de 2007.

ENDERS, W. Applied econometric time series. New York: John Wiley & Sons, 1995.

FAVA, V. L. Manual de econometria. In: VASCONCELOS, M. A. S.; ALVES, D. São Paulo: Editora Atlas, 2000

FOLHA. Sus nos estados não tem leitos de uti contra o coronavirus. Disponível em: <https://www1.folha.uol.com.br/equilibrioesaude/2020/03/susnos-estados-nao-tem-leitos-de-uti-contra-o-coronavirus.shtml>. Acesso em: 1 set. 2020.

GIL, A.C. Como Elaborar Projetos de Pesquisa. 5ed.São Paulo: Atlas, 2010.

GUJARATI, D. N.. Econometria basica. São Paulo: Makron Books, 2000.

Guo YR, Cao QD, Hong ZS, et al. The origin, transmission and clinical therapies on coronavirus disease 2019 (COVID-19) outbreak - an update on the status. Mil Med Res. 2020;7(1):11. doi: <https://doi.org/10.1186/s40779-020-00240-0>

HYNDMAN, Rob Athanasopoulos; ATHANASOPOULOS, George. Forecasting: Principles and Practice. [S. l.: s. n.], 2018. Disponível em: <https://otexts.com/fpp2/>. Acesso em: 3 set 2020.

INTERPRETATION of mean absolute scaled error (MASE)., 17 nov. 2014. Disponível em: <https://stats.stackexchange.com/questions/124365/interpretation-of-mean-absolute-scaled-error-mase>. Acesso em: 5 set 2020.

LATORRE, M. R. D. O; CARDOSO, M. R. A. Análise de séries temporais em epidemiologia: uma introdução sobre os aspectos metodológicos. Rev. Bras. Epidemiol. Vol. 4, Nº 3, 2001.

MAKRIDAKIS, S. G.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. Forecasting: methods and applications. 3^a. ed. New York, USA: Wiley, 1998.

MINISTÉRIO DA SAÚDE. Painel Covid. Disponível em: <https://covid.saúde.gov.br/>. Acesso em: 23 set. 2020.

MORETTIN, P. A.; TOLOI, C. M. C. Previsões de Séries Temporais, 2^a ed. Atual, São Paulo, 1987.

Nicolas. Accuracy module. Disponível em: <https://surprise.readthedocs.io/en/stable/accuracy.html>. Acesso em: 7 set 2020

PELLEGRINI, F.R. & FOGLIATTO, F. Passos para a implantação de sistemas de previsão de demanda – Técnicas e estudo de caso. Revista Produção. Vol. 11, número 1, p.43-64, 2001.

PELLEGRINI, F.R. Metodologia para implementação de sistemas de previsão de demanda – Dissertação de Mestrado em Engenharia de Produção. Porto Alegre: UFRGS, 2000.

RIBEIRO, A. L. Teorias da Administração. São Paulo: Saraiva, 2003.

SARTORIS, A. Estatística e introdução a econometria. São Paulo: Saraiva, 2003.

SILVA, E. L., MENEZES, E. M. (2000) Metodologia da pesquisa e elaboração de dissertação. Programa de Pós Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina, Florianópolis, 2000, 118p.

WERNER, L. & RIBEIRO, J.L.D. Modelo composto para prever demanda através da integração de 11 previsões. Revista Produção. Vol. 16, n. 3, p. 493-509, 2006.

WERNER, L. & RIBEIRO, J.L.D. Previsão de demanda: uma aplicação dos modelos Box Jenkins na área de assistência técnica de computadores pessoais. Revista Gestão e Produção. Vol. 10, n. 1, p. 47-67, 2003.