

APLICAÇÃO DE MODELO ARIMA NA DEMANDA TURÍSTICA INTERNACIONAL DO ESTADO DE MATO GROSSO DO SUL, BRASIL

Bruno Matos Porto - Universidade Federal de Mato Grosso do Sul/CPAQ. bmatosporto@gmail.com

Vanessa Aline Wagner Leite - Universidade Federal de Mato Grosso do Sul/CPAQ/PPGEO.

vanessawleite@gmail.com

Dra. Daniela Althoff Philippi - Universidade Federal de Mato Grosso do Sul/CPAQ.

daniela_philippi@yahoo.com.br

Resumo

O objetivo deste trabalho foi gerar previsões e verificar a precisão no curto prazo do modelo univariado ARIMA, na previsão da demanda de turismo do estado de Mato Grosso do Sul (MS). Com uso do software R, com base nos dados da ferramenta base de dados extrator do Instituto Brasileiro de Turismo (Embratur). Os dados são referentes às chegadas turísticas por todas as vias registradas no MS entre janeiro de 2007 a setembro de 2016. As previsões da demanda turística abrangeram o intervalo de outubro a dezembro de 2016, sendo então comparadas aos dados reais do mesmo período. A previsão do modelo foi comparada por meio dos critérios MAPE, MAD e MSD, onde os resultados gerados pelas medidas de erros mostraram que ARIMA gerou boas previsões. Recomenda-se a estudos futuros executar a previsão da demanda turística com mais modelos de previsão tal como o método de suavização exponencial de (Holt-Winters, 1960) e redes neurais.

Palavras-Chave: Previsão; Séries Temporais; Medida de precisão.

1. Introdução

A atividade turística necessita de um planejamento de previsão de demanda turística (CHU, 1998; SERRA, TAVARES; SANTOS, 2005). Neste enfoque é consenso que planejamento se relaciona com as decisões que serão tomadas e afetará o futuro (GOH; LAW, 2002). As previsões de curto prazo são relevantes para vários objetivos de gestão como bem explicado por Gunter e Önder (2015, p. 123), “previsão de curto prazo da previsão da demanda nos próximos dois ou três meses pode ajudar o destino a ter mais flexibilidade operacional, por exemplo, em termos de número de ônibus do aeroporto para o centro da cidade”.

Diante disto, os serviços turísticos necessitam de um planejamento preditivo que é obtido via predição acurada da demanda turística (GOH, LAW; MOK, 2008). Outro aspecto significativo nos dados da demanda turística é a natureza da sazonalidade que deve ser identificada antes da seleção do modelo de previsão ideal que considere a sazonalidade (GOH; LAW, 2002).

O estudo é importante devido aos impactos do fenômeno turístico na economia do Brasil e sua parte considerável no desenvolvimento econômico e social através de geração de empregos diretos, indiretos e renda (CASANOVA et al., 2012), tendo em vista que a indústria do turismo no Brasil, com base nos dados disponíveis pela Embratur, representa 9% do PIB, assim gerou direta e indiretamente mais de 7,5 milhões de empregos no Brasil, além disso, mantém milhões de micro e pequenas empresas de muitos segmentos da economia (EMBRATUR, 2017d).

A previsão de demanda do turismo é um assunto significativo para os praticantes e acadêmicos (SONG; LI, 2008; KIM et al., 2011; GUNTER; ÖNDER, 2015). A predição de demanda turística desempenha um papel fundamental no planejamento turístico uma vez que os projetos de investimento no turismo que utilizam altos recursos financeiros precisam de uma previsão precisa do que irá ocorrer futuramente com a demanda (CHO, 2003). É amplamente concordado que as regiões específicas precisam de previsões precisas da procura do turismo, mas existem poucas pesquisas, neste sentido, devido à falta de informação estatística (CLAVERIA; TORRA, 2014).

A pesquisa de Chu (1998) aplicou os modelos ARIMA sazonal e não sazonal, *Holt-Winters* nos dados de chegada de turistas nos países da Ásia-Pacífico. Os resultados revelaram que a previsão no curto ou médio prazo de ARIMA sazonal e não sazonal foram os mais acurados dos modelos testados, jugado pelo critério MAPE, assim, testou-se a acuracidade dos modelos ARIMA sazonal e não sazonal, *Holt-Winters*, por meio, de MAPE e receberam um percentual abaixo de 10%.

No estudo de Goh e Law (2002) aplicaram-se os modelos SARIMA e MARIMA, com intervenções nas dez séries temporais de chegadas mensais para Hong Kong de dez países de origem e, para avaliar os desempenhos das previsões, utilizaram-se os índices de desempenho MAD, RMSE, RMSPE, MSE, MAPE e Theil's U. Destacou-se o modelo preditivo MARINA, no entanto depende do mercado de origem, pois em alguns mercados o desempenho individual do modelo SARIMA supera as previsões de MARINA.

Na procura do turismo de Paris compararam-se modelos univariados (ARIMA, ES e Naive 1) e multivariados (VAR clássico e bayesiano, TVP, EC-ADLM) de previsão com a finalidade de avaliar a acuracidade dos sete modelos mediante as medidas de erro RMSE e MAE. Os resultados evidenciaram que todos os modelos testados tiveram melhor desempenho preditivo do que o modelo Naive 1, em vários horizontes de predição e mercados de origem (GUNTER; ÖNDER, 2015).

Na previsão de curto, médio e longo dos dados de chegadas turísticas em países da Europa, através da aplicação dos modelos ARIMA, ETS, NN, TBATS, ARFIMA, MA, WMA, SSA-R e SSA-V. E comparação da acurácia destes modelos pela medida de discrepância RMSE, DC e DM. Constatou-se que em diferentes horizontes de previsão e mercados pesquisados, não identificou um único modelo que tivesse melhor desempenho do que todos os diversos modelos testados em todas as circunstâncias (HASSANI et al., 2017).

O objetivo desta pesquisa foi gerar previsões e verificar a precisão especificamente num único horizonte de três meses à frente e comparar as previsões com os dados reais, por meio, dos critérios MAD, MAPE e MSD. Aplicado o modelo univariado (ARIMA sem intervenção). No contexto turístico nos dados de MS em uma única série temporal de chegadas turísticas internacionais.

2. Fundamentação teórica

Apresentam-se, com base na literatura, demanda turística, ARIMA e medida de precisão.

2.1 Demanda turística

Nas últimas décadas, houve um crescimento significativo da procura do turismo no mundo (GOH; LAW, 2002; SONG; LI, 2008; HASSANI et al., 2017). Além disso, os serviços turísticos têm uma natureza perecível o que estabelece a necessidade de previsão precisa da demanda do turismo (GOH, LAW; MOK, 2008; GUNTER; ÖNDER, 2015).

A predição da demanda turística de uma cidade é fundamental para a estratégia de planejamento do ponto de vista do turismo, que proporciona expansão dos serviços turísticos tanto em investimento de recursos humanos (treinamento) como estrutura física para atender as necessidades das pessoas (CASANOVA et al., 2012). Neste sentido, Claveria e Torra, (2014, p. 220), afirmam que “as previsões precisas do volume do turismo desempenham um papel importante no planejamento do turismo, pois permitem que os destinos prevejam necessidades de desenvolvimento de infraestrutura”.

Alguns motivos para se prever uma futura demanda turística são apontados por Gunter & Önder (2015, p. 123), como:

O quarto do hotel que não é vendido, amanhã será uma perda de receita. Um destino também precisa saber sobre quantos turistas são esperados para que a quantidade de voos para o destino pode ser ajustado, novos hotéis podem ser construídos e funcionários adicionais podem ser contratados.

2.2 Auto-regressive integrated moving average (ARIMA)

Dentre os modelos utilizados para analisar uma série de tempo univariada tem-se o ARIMA. Proposto por Box-Jenkins em 1976, este modelo usa uma combinação de três componentes que são autorregressivo (AR), filtro de integração (I) e médias móveis (MA) (BUNDCHEEN, 2016b).

O modelo ARIMA utilizado nesta pesquisa é uma versão automática chamada de auto.arima. Onde o valor de d é escolhido com base em repetidos testes de raiz de unidade KPSS, em seguida são selecionados os valores de p e q minimizando o Critério de Informação Akaike (AIC) para determinar os valores.

$$\phi(B)(1 - B^d)y_t = c + \theta(B)\varepsilon_t \quad (9)$$

Onde, ε_t é um processo de ruído branco com zero médio e variância σ^2 , B é o operador de mudança de turno, e $\phi(Z)$ e $\theta(Z)$ são polinômios da ordem p e q , respectivamente. Para garantir causalidade e invertibilidade, presume-se que $\phi(Z)$ e $\theta(Z)$ não têm raízes para $|Z| < 1$ (Brockwell e Davis, 1991). Se $c \neq 0$, existe um polinômio implícito de ordem d na função de previsão (HYNDMAN; KHANDAKAR, 2008). O modelo de previsão automático ARIMA seleciona a ordem de p , q e d , por meio do critério de Informação conforme o AIC:

$$AIC = -2 \log(L) + 2(p + q + P + Q + k) \quad (10)$$

Em que $k = 1$ se $c \neq 0$ e 0 de outra forma, e L é a probabilidade máxima do modelo fixado para dados diferidos $(1 - B^m)^D (1 - B)^d y_t$. A probabilidade de o modelo completo para y_t não é realmente definida e, portanto, o valor da AIC para diferentes níveis de difusão não é comparável (HYNDMAN; KHANDAKAR, 2008).

Assim, o algoritmo Hyndman-Khandakar seleciona o modelo que apresenta o menor valor AIC de: ARIMA (2, d , 2), ARIMA (0, d , 0), ARIMA (1, d , 0) e ARIMA (0, d , 1) dentre os quatros modelos (HASSANI et al., 2017). Para os leitores mais interessados nos detalhes de funcionamento da modelagem ARIMA basta ver a seção 8.7 em Hyndman e Athanasopoulos (2013).

2.3 Medida de precisão

Medidas de erro são métodos de se obter informações sobre a robustez da previsão do modelo de previsão em prever os valores reais, tanto para o ajuste do modelo aos dados, quanto a previsão de valores fora da amostra (MAKRIDAKIS, 1993).

Numa pesquisa bibliográfica sobre previsão de demanda turística de 2005 até 2015, com um total de 129 artigos, Bündchen (2016), constatou que *Mean Absolute Percentage Error* (MAPE) é o critério mais usado na predição da procura do turismo. O *Mean Squared Error* (MAD) constitui-se uma das primeiras medidas de erro, sendo singela de calcular e simples de compreender (BONETT; SEIER, 2003).

MAPE e MAD são indicadores de desempenho que geram a diferença entre o real e o previsto, neste sentido, quanto menor os valores gerados pelos indicadores, melhor é a acuracidade das previsões (SAFARI; DAVALLOU, 2018).

O MAPE é uma medida de erro estatística que gera informações de erro de previsão em porcentagem, além disso, é simples de calcular e simples de compreender (DAS, MISHRA; ROUT, 2017). Assim, MAPE é muito utilizado pela sua facilidade de interpretação (DE MYTTENAERE et al., 2016), por ser fácil de interpretação o MAPE é um dos critérios mais conhecidos de acuracidade da predição (KIM; KIM, 2016). MAD é classificado na previsão de série de tempo como um critério básico de erro de previsão (DAS, MISHRA; ROUT, 2017).

O *Mean Squared Error* (MSE) mede o erro quadrático, os resultados de MSE quanto mais próximo de zero é melhor também apresenta a diferença entre o valor real e o valor previsto e geralmente é utilizado para verificar como o modelo de previsão se ajustou as observações (DAS, MISHRA; ROUT, 2017).

$$MAD = \frac{\sum |R-D|}{n} \quad (11)$$

$$MSD = \frac{\sum (R-D)^2}{n-1} \quad (12)$$

$$MAPE = \frac{\sum |R-D/R|}{n} \cdot 100, (R \neq 0) \quad (13)$$

Fonte: Adaptado de Da Silveira Bueno, (2008)

Sendo, R = valor real de demanda; D = previsão; n = número de observações.

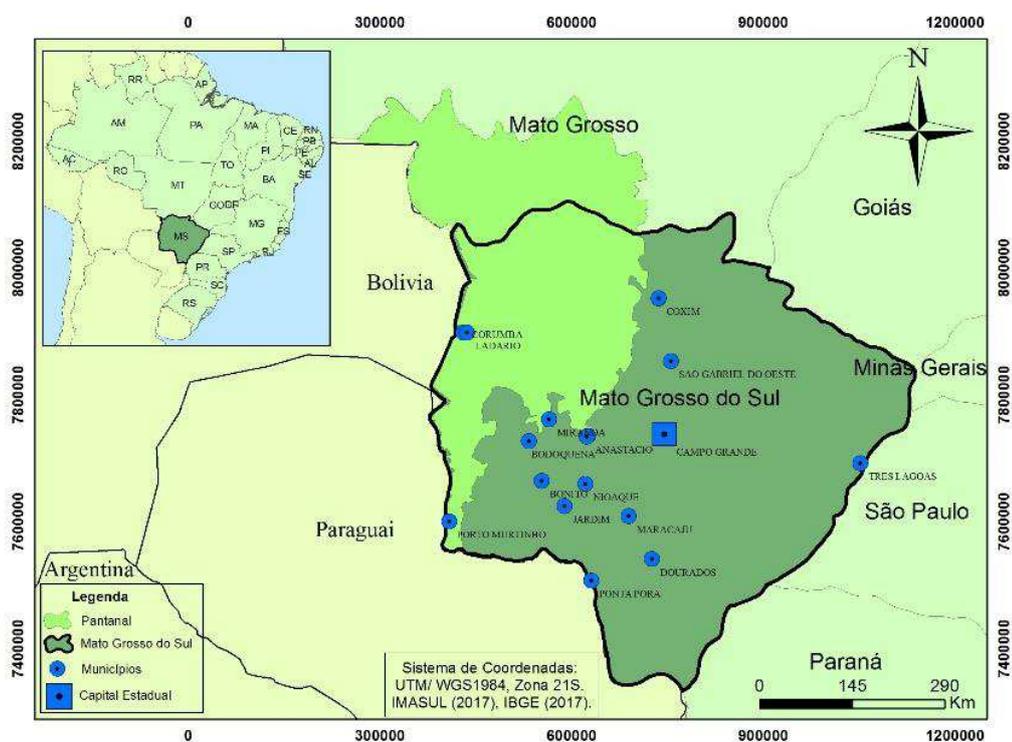
3. Procedimentos metodológicos

Essa seção apresenta-se a área de estudo, coleta de dados e o pacote usado no ambiente de trabalho R studio.

3.1 Área de estudo

O Estado do Mato Grosso do Sul (Figura 2), localizado no centro-oeste brasileiro, possui cerca de 357.145,531 Km² e conta com uma população estimada em mais de 2,5 milhões de habitantes (IBGE, 2016). Situado em região transfronteiriça com Paraguai e Bolívia a Oeste, faz divisa com os Estados brasileiros Paraná, São Paulo, Minas Gerais e Goiás a Leste e o Estado de Mato Grosso ao Norte.

Figura 1 - Localização do Estado de Mato Grosso do Sul, Brasil



Fonte: Elaborado pelos autores através do software ARCGIS (2012)

O Estado encontra-se em parte inserido em uma importante unidade geológica como a Bacia Sedimentar do Pantanal que lhe confere potencialidades turísticas manifestadas nos municípios de Corumbá, Miranda e Aquidauana correspondendo ao Pantanal e nos municípios de Bodoquena, Bonito e Jardim pela relevância de seu ambiente cárstico (MATO GROSSO DO SUL, 2017). localizado na zona de transição da borda do Pantanal sul-matogrossense. Essa unidade representa também um importante cenário hidrográfico, além da riqueza em sua biodiversidade e da beleza paisagística.

O Pantanal sendo a maior planície alagável do mundo e patrimônio da humanidade segundo a UNESCO (MATO GROSSO DO SUL, 2017), abrange entre suas atividades turísticas o

ecoturismo, buscando realizar suas atividades de maneira sustentável preservando e conservando as belezas naturais. O turismo cultural relacionadas a festas e eventos culturais do estado, o turismo de pesca esportiva em virtude da riqueza fluvial do rio Paraguai e seus afluentes. Suas atividades contam com pousadas pantaneiras que oferecem pacotes para contemplação da fauna e flora, passeios de chalanas pelos rios da bacia hidrográfica do rio Paraguai, observação de aves típicas da região, Safaris e Voos panorâmicos (ROTTA, 2006).

Adjacente ao Pantanal, devido ao seu relevo cárstico e rochas carbonáticas, a região de Bodoquena, Bonito e Jardim possuem peculiaridades turísticas através de seus “rios de águas cristalinas que abrigam exuberante fauna ictiológica; cachoeiras, fauna terrestre, flora; grutas e ainda pelo contraste da planície com a Serra da Bodoquena” (BARBOSA e ZAMBONI, 2000, p. 06) apresentando “inúmeras cavernas, dolinas, ressurgências e sumidouros, dentre outras feições, além de promover uma extrema limpidez dos cursos d’água que nela têm suas nascentes” (MATO GROSSO DO SUL, 2010, p. 15).

3.2 Coleta de dados

Os dados foram coletados a partir da ferramenta base de dados extrator que de acordo com o (Embratur, 2017a) é:

O extrator de dados sobre a Chegada de turistas internacionais não residentes ao Brasil é uma ferramenta eletrônica interativa que representa importante incremento na disseminação de informações sobre o setor turismo relativas Brasil, unidades da federação, regiões.

Além disso, serve para “A série disponibilizada permite o acompanhamento da evolução do fluxo receptivo internacional de turistas, e dá ao usuário a flexibilidade, rapidez, precisão e consistência de informações que a análise gerencial de informações requer” (EMBRATUR, 2017b). Um detalhe importante sobre a coleta e a ferramenta é que “O extrator de dados é uma customização do Saiku, software de código aberto para análise de dados desenvolvida pela Meteorite BI” (EMBRATUR, 2017c).

Tanto a ferramenta como as informações sobre a mesma são disponibilizadas pelo Instituto Brasileiro de Turismo (Embratur) no site da Embratur, portanto mediante a ferramenta a coleta foi referente às chegadas turísticas por todas as vias (totais) dos períodos de janeiro de 2007 a setembro de 2016, atingindo 117 períodos mensais de amostra. Os dados utilizados encontram-se no quadro 1:

Quadro 1 - Chegadas turísticas internacionais por todas as vias para Mato Grosso do Sul de janeiro de 2007 a setembro de 2016

Mês/Ano	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016
Janeiro	6.888	6.715	19.747	21.260	5.477	7.314	6.031	8.454	7.542	12.544
Fevereiro	5.412	6.073	13.896	15.066	4.469	3.205	4.165	5.129	4.994	6.687
Março	4.583	6.252	13.527	14.540	2.890	4.314	4.129	3.909	4.400	6.011
Abril	3.406	2.922	3.821	4.167	4.045	2.993	3.144	4.302	4.533	5.003
Mai	3.716	3.243	1.162	2.952	3.072	1.897	2.290	4.085	3.697	4.262
Junho	3.080	2.675	955	3.244	2.142	4.196	2.269	6.905	3.250	4.278
Julho	5.957	3.462	2.035	2.221	2.528	4.072	3.694	4.512	4.941	6.212
Agosto	5.946	3.702	1.401	1.538	1.402	2.919	2.817	3.867	3.508	5.398
Setembro	3.542	3.070	964	1.058	1.467	2.545	1.230	3.488	1.636	4.973
Outubro	3.660	2.746	361	652	2.866	2.309	2.745	3.334	4.192	-
Novembro	3.809	3.431	269	876	3.241	1.732	2.945	3.732	4.225	-
Dezembro	5.210	5.217	257	566	5.501	6.395	6.064	10.282	9.683	-

Fonte: Adaptada pelos autores a partir de EMBRATUR (2017)

Após a coleta da amostra para avaliar a normalidade desta amostra foi aplicada a estatística Shapiro-Wilk Test (SWT) em R usando a função *shapiro.test* para detectar a distribuição normal na amostra. O Shapiro-Wilk Test (SWT) é um poderoso e competitivo teste para a normalidade (LEE, QIAN; SHAO, 2014). Realizado o *shapiro.test* e analisado os resultados apresentados na tabela 1. Verifica-se que a amostra possui uma distribuição normal.

Tabela 1 - Resultado Shapiro-Wilk Test (SWT)

Shapiro-Wilk	W	p-value
	0.76	1.512e-12

Fonte: Elaborada pelos autores

3.3 Pacote em R studio

Para fazer as previsões e verificar a precisão do modelo ARIMA, foi adotado com o apoio do software estatístico R. Procedeu-se as análises de previsão e acuracidade das previsões no *R studio* que é uma extensão do ambiente R, mediante o pacote *forecast* do R. Os cálculos das medidas de erro MAD, MAPE e MSD também foram executados com o pacote *forecast* no *R studio*.

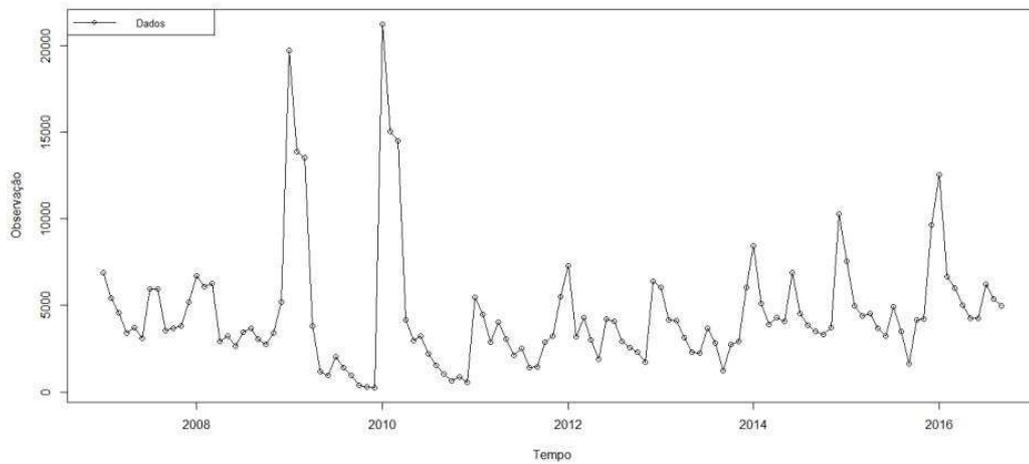
A função em R utilizada para prever os valores no curto prazo é *auto.arima*, (HYNDMAN; KHANDAKAR, 2008; HYNDMAN, 2017). Já para verificar a acuracidade do modelo de previsão foi usada a função *accuracy*. Assim, contemplando o período entre janeiro de 2007 até setembro de 2016, verificou-se o comportamento das previsões com os dados reais que

foram disponibilizados pela Embratur pertencentes ao período de outubro a dezembro de 2016.

4. Resultados e discussões

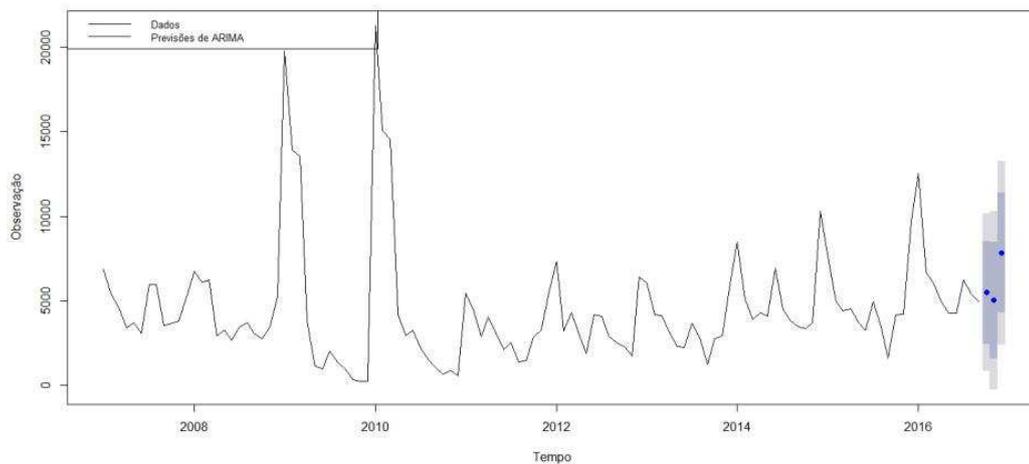
A princípio procedeu-se a criação de um gráfico de série temporal mediante os dados coletados de chegadas turísticas e atendem-se as orientações de Hyndman e Athanasopoulos (2013), que recomendam inicialmente mostrar os dados em gráfico, construiu-se o gráfico de série temporal representado na figura 2.

Figura 2 - Chegadas turísticas internacionais por todas as vias



Fonte: Elaborado pelos autores através do software R e com base em dados da EMBRATUR (2017)

Figura 3 - Previsões de ARIMA de outubro até dezembro de 2016



Fonte: Elaborado pelos autores com software R (2017)

O parâmetro do modelo ARIMA selecionado com o menor critério de informação akaike (AIC) estes referentes às previsões são demonstradas na tabela 2.

Tabela 2 - Parâmetro de previsões do modelo ARIMA

ARIMA
(1,0,0) (1,0,0)

Fonte: elaborada pelos autores

O modelo descrito foi utilizado para gerar as previsões de 3 meses das chegadas turísticas. As observações e ARIMA em números para os meses de outubro até dezembro de 2016 podem ser visualizadas no quadro 2.

Quadro 2 - Comparação dos valores previstos com dados reais

Meses	Dados reais	ARIMA
Outubro	4.946	5.495,44
Novembro	5.716	5.021,20
Dezembro	10.998	7.843,58

Fonte: elaborada pelos autores com base em EMBRATUR (2017)

As medidas de erro MAPE, MAD e MSD apresenta a precisão do modelo em comparação com os dados reais.

Tabela 3 - Medidas de erro

Modelo	MAPE	MAD	MSD
ARIMA	17.31526%	1099,92570	3578332,30

Fonte: elaborada pelos autores

O ARIMA teve um desempenho razoável com base nos resultados dos critérios MAPE, MAD e MSD como pode ser observada na tabela 3. De acordo com as diretrizes de Lewis (1982), os resultados de MAPE entre 10% e 20% são interpretados como previsão precisa, diante disso, ARIMA apresentou boas previsões.

5. Considerações finais

O resultado da pesquisa mostrou-se que ARIMA fornece boas previsões da demanda turística internacional de Mato Grosso do Sul, indicando a possibilidade de utilização do modelo ARIMA para prever a demanda turística de Mato Grosso do Sul, pelos planejadores turísticos da região. A limitação da pesquisa foi aplicar um único modelo de previsão. Para superar essa limitação sugere-se a estudos futuros executar a previsão da demanda turística com mais modelos de previsão tal como o método de suavização exponencial de (Holt-Winters, 1960) e redes neurais.

Referências

ARCGIS, ESRI. 10.1. Redlands, California: ESRI, 2012.

BARBOSA, Maria Alice Cunha; ZAMBONI, Roberto Aricó. Formação de um 'cluster' em torno do turismo de natureza sustentável em Bonito–MS. 2000. p. 06. Disponível em: <<https://goo.gl/9JFCiM>> Acesso em: 14 Ago 2017.

BONETT, Douglas G.; SEIER, Edith. Statistical inference for a ratio of dispersions using paired samples. **Journal of Educational and Behavioral Statistics**, v. 28, n. 1, p. 21-30, 2003.

BROCKWELL, Peter J.; DAVIS, Richard A. **Time series: theory and methods**. Springer-Verlag, 2nd edition, New York, 1991.

BÜNDCHEN, Cristiane. **Previsão de demanda turística e a acurácia das previsões frente à realização de megaeventos**. Dissertação (Mestrado em Engenharia de Produção) - Escola de Engenharia, Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016.

BUNDCHEN, Cristiane; WERNER, Liane. Comparação da Acurácia de Previsões de Demanda Turística em Sedes Olímpicas. **Revista Turismo em Análise**, v. 27, n. 1, p. 85-107, 2016. (b)

CASANOVA, Sidnei et al. PREVISÃO DA DEMANDA TURÍSTICA DA CIDADE DE FOZ DO IGUAÇU: UMA APLICAÇÃO COM OS MODELOS ARIMA. **Turismo: Visão e Ação**, v. 14, n. 3, 2012.

CHO, Vincent. A comparison of three different approaches to tourist arrival forecasting. **Tourism management**, v. 24, n. 3, p. 323-330, 2003.

CHU, Fong-Lin. Forecasting tourism demand in Asian-Pacific countries. **Annals of Tourism Research**, v. 25, n. 3, p. 597-615, 1998.

CLAVERIA, Oscar; TORRA, Salvador. Forecasting tourism demand to Catalonia: Neural networks vs. time series models. **Economic Modelling**, v. 36, p. 220-228, 2014.

DA SILVEIRA BUENO, Rodrigo De Losso. **Econometria de séries temporais**. Cengage Learning, 2008.

DAS, Smruti Rekha; MISHRA, Debahuti; ROUT, Minakhi. A hybridized ELM-Jaya forecasting model for currency exchange prediction. **Journal of King Saud University-Computer and Information Sciences**, 2017.

DE MYTTENAERE, Arnaud et al. Mean absolute percentage error for regression models. **Neurocomputing**, v. 192, p. 38-48, 2016.

EMBRATUR. Acesse o EXTRATOR DE DADOS. Disponível em: <<https://goo.gl/TNuk1X>> Acesso em: 29 Jun. 2017.

EMBRATUR. O QUE É. Disponível em: <<https://goo.gl/SqyAao>> Acesso em: 29 Jun. 2017a.

EMBRATUR. PARA QUE. Disponível em: <<https://goo.gl/4WrFcu>> Acesso em: 29 Jun. 2017b.

EMBRATUR. TERMOS E CONDIÇÕES DE USO. Disponível em: <<https://goo.gl/k6Wgx5>> Acesso em: 29 Jun. 2017c.

EMBRATUR. Turismo já ajudou países a superar crises e pode fazer o mesmo no Brasil. Disponível em: <<https://goo.gl/QwCPQy>> Acesso em: 22 Jun. 2017d.

- GOH, C; LAW, R; MOK, H.M.K. Analyzing and forecasting tourism demand: A rough sets approach. **Journal of Travel Research**, v.46, n.3, p.327-338, 2008.
- GOH, Carey; LAW, Rob. Modeling and forecasting tourism demand for arrivals with stochastic nonstationary seasonality and intervention. **Tourism management**, v. 23, n. 5, p. 499-510, 2002.
- GUNTER, Ulrich; ÖNDER, Irem. Forecasting international city tourism demand for Paris: Accuracy of uni-and multivariate models employing monthly data. **Tourism Management**, v. 46, p. 123-135, 2015.
- HASSANI, Hossein et al. Forecasting accuracy evaluation of tourist arrivals. *Annals of Tourism Research*, v. 63, p. 112-127, 2017.
- HYNDMAN, Rob J. *forecast: Forecasting functions for time series and linear models*. R package version 8.2, 2017. **Disponível em:** <<https://goo.gl/nykh6h>> Acesso em: 01 Nov. 2017.
- HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting: principles and practice**. Seção 1/6. OTexts, 2013. **Disponível em:** <<https://goo.gl/R1Xdu8>> Acesso em: 01 Jul. 2017.
- HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting: principles and practice**. Seção 8/7. OTexts, 2013. **Disponível em:** <<https://goo.gl/QiimWh>> Acesso em: 20 Jul. 2017.
- HYNDMAN, Rob J.; KHANDAKAR, Yeasmin. Automatic time series forecasting: the forecast package for R. **Journal of Statistical Software**, v. 27, n. 3, p. 1–22, 2008.
- IBGE - Instituto Brasileiro de Geografia e Estatística. Estados. **Disponível em:** <<https://goo.gl/arjBQb>>. Acesso em: 23 Nov. 2017.
- KIM, Jae H. et al. Beyond point forecasting: evaluation of alternative prediction intervals for tourist arrivals. *International Journal of Forecasting*, v. 27, n. 3, p. 887-901, 2011.
- KIM, Sungil; KIM, Heeyoung. A new metric of absolute percentage error for intermittent demand forecasts. **International Journal of Forecasting**, v. 32, n. 3, p. 669-679, 2016.
- LEE, Richie; QIAN, Meng; SHAO, Yongzhao. On rotational robustness of Shapiro-Wilk type tests for multivariate normality. **Open Journal of Statistics**, v. 4, n. 11, p. 964, 2014.
- LEWIS, Colin David. **Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting**. Butterworth-Heinemann, 1982.
- MAKRIDAKIS, Spyros. Accuracy measures: theoretical and practical concerns. **International Journal of Forecasting**, v. 9, n. 4, p. 527-529, 1993.
- MATO GROSSO DO SUL. BODOQUENA-PANTANAL, GEOPARK. Dossiê de candidatura à Rede Global de Geoparks Nacionais sob auspício da Organização das Nações Unidas para Educação, Ciências e Cultura. 2010. **Disponível em:** <<https://goo.gl/7sSUrg>> Acesso em: 14 Ago 2017.
- MATO GROSSO DO SUL. Fundação de Turismo de MS–FUNDTUR. Indicadores Turísticos de MS. **Disponível em:** <<https://goo.gl/h8icqB>> Acesso em: 14 Ago 2017.
- ROTTA, Marco Aurélio; LUNA, Helder Silva e.; WEIS, Wilson Antonio. Ecoturismo no Pantanal. **Corumbá: Embrapa Pantanal**, 2006. **Disponível em:** <<https://goo.gl/Eh6YRe>> Acesso em: 14 Ago 2017.
- SAFARI, Ali; DAVALLOU, Maryam. Oil price forecasting using a hybrid model. **Energy**, 2018.

SERRA, Cláudio Mauro Vieira; TAVARES, Heliton Ribeiro; SANTOS, Julio César Correa. Aplicação de séries temporais na análise de demanda turística no Estado do Pará usando os modelos de Holt-Winters. **XXV Encontro Nacional de Engenharia de Produção**, 2005.

SONG, Haiyan; LI, Gang. Tourism demand modelling and forecasting—A review of recent research. *Tourism management*, v. 29, n. 2, p. 203-220, 2008.