

Análise em séries temporais da radiação solar na Cidade do Recife/PE
Time series analysis of solar radiation in the City of Recife/PE
Análisis de series temporales de radiación solar em la Ciudad de Recife/PE

Recebido: 19/07/2020 | Revisado: 04/08/2020 | Aceito: 07/08/2020 | Publicado: 14/08/2020

Jucarlos Rufino de Freitas

ORCID: <https://orcid.org/0000-0002-3497-4263>

Universidade Federal Rural de Pernambuco, Brasil

E-mail: jucarlos123@hotmail.com

Ruben Vivaldi Silva Pessoa

ORCID: <https://orcid.org/0000-0003-1469-5918>

Universidade Federal Rural de Pernambuco, Brasil

E-mail: rvsp1@de.ufpe.br

Mickaelle Maria de Almeida Pereira

ORCID: <https://orcid.org/0000-0003-4891-6184>

Universidade Federal Rural de Pernambuco, Brasil

E-mail: mickaellealmeida1@gmail.com

Leika Irabele Tenório de Santana

ORCID: <https://orcid.org/0000-0002-5516-5887>

Universidade Federal Rural de Pernambuco, Brasil

E-mail: leikatenorio10@gmail.com

Joelma Mayara da Silva

ORCID: <https://orcid.org/0000-0003-2354-6068>

Universidade Federal Rural de Pernambuco, Brasil

E-mail: jms.estat@gmail.com

Moacyr Cunha Filho

ORCID: <https://orcid.org/0000-0002-3466-8143>

Universidade Federal Rural de Pernambuco, Brasil

E-mail: moacyr.cunhafo@ufrpe.br

Resumo

Objetivo: analisar e descrever o melhor ajuste para série temporal de radiação solar na cidade do Recife/PE, aplicando os modelos ARMA e ARMAX, além de prever os níveis de radiação

para os próximos seis anos. Método: utilizaram-se dados de séries climáticas do Instituto Nacional de Meteorologia (INMET), disponibilizados no período de janeiro de 2009 a dezembro de 2018. A comparação dos modelos foi realizada pelos critérios de informação de Akaike. Resultados: a série de radiação solar apresenta uma alta variabilidade das médias mensais, indicando a presença de sazonalidade e uma forte assimetria negativa. Os resultados da estatística de erros mostram a acurácia do modelo ARMAX(2,1), com erro percentual próximo de 18,68%, comparando-se a série observada e ajustadas, além disso, foi possível identificar que a previsão consegue captar a existência de sazonalidade. Conclusão: o modelo ARMAX foi adequado para descrever a radiação solar incluindo variáveis exógenas, apresentando melhor previsão com boa acurácia, sendo uma ferramenta capaz de auxiliar em políticas de saúde pública no combate ao câncer de pele e intervenções.

Palavras-chave: Radiação solar; Mudanças climáticas; Modelagem; Previsão.

Abstract

Objective: analyze and describe the best fit for time serie of solar radiation in the city of Recife/PE, applying the ARMA and ARMAX models, in addition to forecasting radiation levels for the next six years. Method: used climate series data of the National Institute of Meteorology (INMET), available from January 2009 to December 2018. The comparison of the models was performed by Akaike's information criteria. Results: the series of solar radiation presents a high variability of the monthly averages, indicating the presence of seasonality and a strong negative asymmetry. The results of the error statistics show the accuracy of the ARMAX model (2.1), with a percentage error close to 18.68%, comparing the observed and adjusted series, in addition, it was possible to identify that the forecast manages to capture the existence seasonality. Conclusion: ARMAX model was adequate to describe a solar radiation including exogenous variables, being a tool capable of assisting in public health policies in the fight against skin cancer and interventions.

Keywords: Solar radiation; Climate change; Modeling; Forecast.

Resumen

Objetivo: analizar y describir el mejor ajuste para la serie temporal de radiación solar en la ciudad de Recife / PE, aplicando los modelos ARMA y ARMAX, además de predecir los niveles de radiación para los próximos seis años. Método: se utilizaron datos del Instituto Meteorológico Nacional (INMET), disponible desde enero de 2009 hasta diciembre de 2018. Los modelos se compararon utilizando los criterios de información de Akaike. Resultados: la

serie de radiación solar presenta una alta variabilidad de los promedios mensuales, lo que indica la presencia de estacionalidad y una fuerte asimetría negativa. Los resultados de las estadísticas de error muestran la precisión del modelo ARMAX (2.1), con un error porcentual alrededor del 18.68%, comparando las series observadas y ajustadas, además, fue posible identificar que el pronóstico es capaz de capturar la existencia. Conclusión: el modelo ARMAX se adaptó para describir la radiación solar incluidas las variables exógenas, presentando un mejor pronóstico con buena precisión, siendo una herramienta capaz de ayudar a las políticas de salud pública en la combatir el cáncer de piel y la intervención.

Palabras clave: Radiación solar; Cambio climático; Modelado; Pronóstico.

1. Introdução

Mudanças ambientais, geram desequilíbrios socioambientais expressivos e trazem preocupação para população, uma vez que problemas ligados ao meio ambiente podem comprometer a qualidade de vida (de Souza et al., 2011).

Nas pesquisas ligadas aos problemas ambientais, variáveis climáticas como umidade relativa do ar, temperatura e a precipitação pluviométrica têm sido amplamente estudadas e relacionadas à saúde da população (Peng, Xiao-Ming, & Qi-Yong, 2020; Santos et al, 2017; Sobral et al, 2020; Souza et al, 2018). Diante disso, o estudo de radiação solar se faz importante, pois a radiação solar está ligada as variações sazonais da temperatura (Spokas, 2006).

Conforme Gómez et al. (2018), a radiação solar é o fluxo de energia gerada pelo Sol e transmitida na forma de radiação eletromagnética. Ela depende não só das condições atmosféricas como a nebulosidade e a umidade relativa do ar, mas também da latitude local e da posição no tempo (horário e dia do ano).

A preocupação em estudar a radiação é de grande relevância, pois a ocorrência desse fenômeno na sua forma mais aguda em determinada localidade pode acarretar numa influência expressiva de processos foto-oxidativos de outras substâncias presentes na atmosfera que contribuem na formação dos Compostos Carbonílicos, que são responsáveis por lançar os poluentes diretamente na atmosfera (Rocha, 2017). Além da radiação estar relacionada a enfermidades dentre as quais destaca-se a ocorrência de câncer de pele com alto número de incidências no Brasil (Instituto Nacional de Câncer-INCA). Ela também obtém uma ligação com doenças renais (Tawatsupa et al., 2012).

Apesar da importância que o tema possui, ainda existem poucos estudos que ajudem a entender a real situação da radiação no Brasil. Diante do exposto, o trabalho tem como objetivo

analisar, dentre os modelos ARMA e ARMAX, qual apresenta o melhor ajuste para os dados de radiação do município de Recife, e a partir desse modelo, prever os níveis da radiação para os próximos seis anos.

2. Metodologia

Foram utilizados dados disponibilizados pelo Instituto Nacional de Meteorologia (INMET), para analisar, dentre os modelos ARMA e ARMAX, o melhor modelo capaz de prever o nível de radiação solar para seis anos na cidade do Recife/PE, a partir das variáveis exógenas: umidade do ar, temperatura, velocidade do vento, rajada do vento, direção do vento, temperatura de ponto de orvalho, precipitação, pressão atmosférica do município de Recife no período de 2009 a 2018.

Os dados horários disponibilizados pelo INMET foram agrupados para obtenção de medidas diárias, onde no caso da precipitação utilizou-se o acumulado diário e para as demais séries utilizou-se a média diária. Os dados faltantes foram interpolados pela média das últimas 10 observações.

2.1. Série temporal

Uma série temporal é um conjunto de observações ordenadas no tempo cuja notação é representada por $Z_t = \{z_t \in R | t = 1, 2, \dots, N\}$, não necessariamente igualmente espaçadas, que apresentam dependência serial. Antes da definição do modelo se faz necessário analisar os pressupostos estatístico, a citar: estacionariedade, normalidade e sazonalidade (Morettin & Toloi, 2004).

2.2. Dicker-Fuller Aumentado

Com o interesse de averiguar se o processo é estritamente estacionário fez-se necessário aplicar o teste de Dickey-Fuller Aumentado (ADF), em que investiga se o modelo ΔZ_t tem ou não raiz unitária (Gujarati & Porter, 2011). O teste consiste em estimar o modelo

$$\Delta Z_t = \beta_1 + \beta_2 t + \delta Z_{t-1} + \sum_{i=1}^m \alpha \Delta Z_{t-1} + u_i \quad (1)$$

em que β_1 representa o drift da série, β_2 e δ são os coeficientes de tendência e presença de raiz unitária, α é o coeficiente associado a ΔZ_{t-1} , m é o número de defasagens tomadas na série e u_i o ruído branco. Logo, define-se as seguintes hipóteses:

H_0 : A série não é estacionária;

H_1 : A série é estacionária.

Desse modo, sob H_0 a estatística do teste T é dada por:

$$T = \frac{\hat{\delta}}{S_{\hat{\delta}}} \quad (2)$$

em que δ é o estimador do parâmetro associado à sua defasagem para o processo autorregressivo $S_{\hat{\delta}}$ é o desvio padrão dos parâmetros $\hat{\delta}$. Sob H_0 , se $T < T_c$ rejeita H_0 , em que T_c é calculado por Dickley e Fuller através de simulação Monte Carlo.

2.3. Shapiro-Wilk

O teste Shapiro-Wilk (SW) (1965) foi desenvolvido para testar se uma amostra aleatória de tamanho n segue Distribuição Normal, em que o teste de SW depende da correlação entre os dados fornecidos e seus escores normais correspondentes, cujo as hipóteses são definidas por:

H_0 : A amostra provém de uma população Normal;

H_1 : A amostra não provém de uma população Normal.

A estatística do teste W é calculada de acordo com a seguinte equação:

$$W = \frac{(\sum_{i=1}^n a_i x_{(i)})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (3)$$

em que $x_{(i)s}$ são os valores amostrais ordenados, a_i são as constantes geradas das médias, \bar{X} é a média amostral e n é o número de observações (Shapiro & Wilk, 1965).

Sob H_0 , se $W > W_{(\alpha,n)}$ ou $P(W > W_{(\alpha,n)}) > \alpha$ não rejeita-se H_0 , logo a amostra provém da distribuição Normal com nível de 5% de significância, em que $W_{(\alpha,n)}$ é o valor tabular usado para comparar com o valor da estatística W .

2.4. Kruskal-Wallis

O teste não paramétrico de Kruskal-Wallis é usado para averiguação de sazonalidade (Provenza; da Serra Costa; de Carvalho Silva, 2018; Kruskal & Wallis, 1952), em que se verifica o padrão da série ao longo do tempo, sendo observada através de gráfico pelo conhecimento preexistente do comportamento da série temporal. A primeira etapa é a construção das hipóteses definida por:

H_0 : Não há sazonalidade determinística;

H_1 : Há sazonalidade determinística.

Admitindo que as observações foram coletadas em períodos de tempo com espaçamentos iguais, cada coluna K é classificada como uma amostra de tamanho n_i , assim tem-se:

$$Z_{ij}, j = 1, \dots, k; i = 1, \dots, n_j. N = \sum_{j=1}^K n_j \quad (4)$$

em que k representa os anos e n_j são os meses e N são todas as observações. Em seguida substitui as observações Z_{ij} pelos referentes postos R_{ij} de todas as N observações e calcula-se a soma de todos os postos em cada subgrupo j (R_j) dado por:

$$R_j = \sum_{i=1}^{n_j} R_{ij}, j = 1, \dots, K \quad (5)$$

Assim, sob H_0 , a estatística do teste é dada por

$$H = \frac{\frac{12}{N(N+1)} \sum_{j=1}^k \frac{R_j^2}{n_j} - 3(N+1)}{1 - \frac{\sum_{i=1}^g t_j^3 - t_j}{N^3 - N}} \quad (6)$$

em que t é o número de observações repetidas no grupo j e g é o número de grupos com observações repetidas.

Sob H_0 , para n_j suficientemente grande, ou $k \geq 4$, a distribuição de H pode ser aproximada por uma distribuição Qui-quadrado com $n-1$ graus de liberdade. Logo, rejeita-se H_0 se $P_{H_0}(H \geq \chi_{(n-1, \alpha)}^2)$, em que α é o nível de significância definido por 5% (Morettin & Toloi, 2004; Box et al., 2015).

2.5. Modelo ARMA

O modelo ARMA (p, q) é descrito como uma combinação dos modelos auto-regressivo (AR) e de médias móveis (MA), em que p diz respeito ao número de defasagens da série e q é o número de defasagens dos erros aleatórios (da Silva, 2019). Assim, tratando-se de uma série temporal Y_t e considerando-se suas primeiras diferenças $Y_t = Y_t - Y_{t-1}$, pode-se expressar o modelo ARMA (p, q) da seguinte maneira:

$$Y_t = \sum_{j=1}^p \phi_j Y_{t-j} + \sum_{k=1}^q \theta_k \epsilon_{t-k} + \epsilon_t \quad (7)$$

em que $\sum_{k=1}^q \theta_k \epsilon_{t-k}$ é a componente das médias móveis do modelo, $\sum_{j=1}^p \phi_j Y_{t-j}$ é a componente auto regressiva do modelo ϵ_t é um ruído branco (Handoyo et al., 2017; da Silva Tabosa et al., 2019).

2.6. Modelo ARMAX

O modelo auto-regressivo de média móvel com variáveis exógenas (ARMAX) é definido como:

$$Y_t = \beta X_{w,t}^t + \sum_{j=1}^p \phi_j Y_{t-j} + \sum_{k=1}^q \theta_k \epsilon_{t-k} + \epsilon_t \quad (8)$$

em que Y_t é a variável endógena no tempo, $X_{w,t}^t$ é o vetor de variáveis exógenas explicativas, w é o número de variáveis exógenas, Y_{t-j} é a variável endógena com p defasagens no tempo, β é o vetor dos coeficientes das variáveis exógenas; $\sum_{k=1}^q \theta_k \epsilon_{t-k}$ é a componente das médias móveis do modelo, $\sum_{j=1}^p \phi_j Y_{t-j}$ é a componente auto regressiva do modelo e ϵ_t é um ruído branco (da Silva Tabosa et al., 2019).

Esses modelos são recomendados para séries com pelo menos 50 observações, e muito vantajosos para previsão a curto prazo. Por outro lado, possuem a desvantagem de poderem ser aplicados apenas em séries estacionárias ou que possam ser transformadas em estacionárias (Box et al., 2015; Morettin & Toloi, 2004).

Para a seleção do melhor modelo foi utilizado o critério *Akaike Information Criteria* (AIC) proposto por Akaike (1974), dado por:

$$AIC = \ln(\hat{\sigma}_\epsilon^2) \frac{2(p+q)}{n} \quad (9)$$

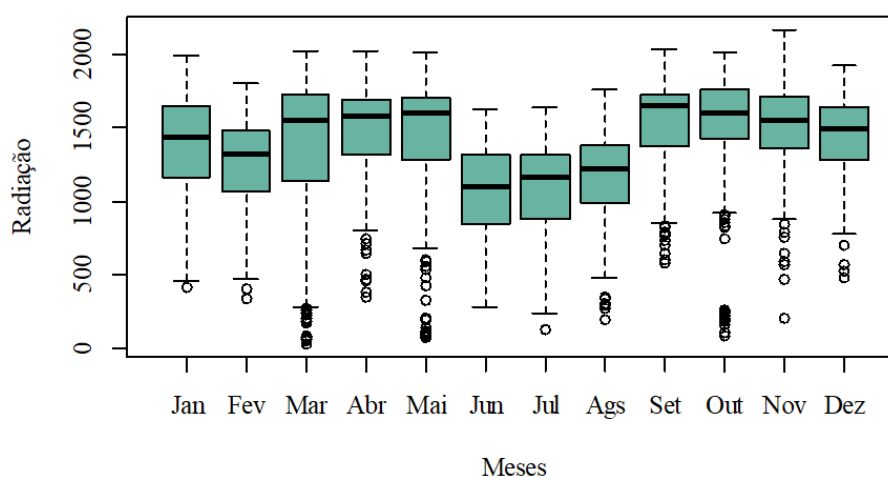
em que levam em conta a variância do erro, o tamanho da amostra e os valores dos parâmetros estimados. A partir do valor do critério AIC, escolher o modelo mais adequado para realizar previsões h-passos à frente. Assim como, as estatísticas Mean Absolute Error (MAE), o Root Mean Square Error (RMSE) e a Mean Absolute Percentage Error (MAPE) são informações importantes para compararmos os modelos de suavização e decidirmos se estes representam um bom ajuste aos nossos dados (Willmott & Matsuura, 2005).

3. Resultados e Discussão

Apresenta-se na Figura 1 o *Box Plot* da radiação solar mensal na cidade do Recife/PE. Neste é possível verificar que o mês de setembro apresenta a mediana mais alta (1494,31 km/m^2), enquanto, o mês de junho a mais baixa com 1163,21 km/m^2 . Os coeficientes de variação apresentaram-se de 18,35% a 42,89%, indicando uma alta variabilidade das médias mensais, no conjunto de 10 anos observados, sugerindo a presença de sazonalidade e uma forte assimetria negativa. O estudo realizado por de Souza et al. (2019), demonstrando que o mês de

setembro tem os maiores valores de radiação solar global com assimetria a esquerda, em que propôs distribuições estatísticas mais prováveis para modelar a radiação solar, a citar: Weibull, Rayleigh, Gamma, Lognormal e Rician.

Figura 1. *Box Plot* da radiação solar mensal em Recife, PE, no período de janeiro de 2009 a dezembro de 2018.



Fonte: Elaborada pelos Autores (2020).

Na Tabela 1, estão os resultados da aplicação dos respectivos testes, Shapiro-Wilk, DickeyFuller e o de Kruskal-Wallis para a cidade do Recife/PE. Os resultados apresentados corroboram com a análise da Figura 1, isto é, devido a influência dos *outliers*, verifica-se o comportamento de ausência de normalidade dos dados. Pode-se verificar que o teste da raiz unitária e sazonalidade apresentou, para a cidade do Recife, que a série é estacionária e apresenta um comportamento sazonal determinístico ao nível de 10% de significância.


Tabela 1. Resultados obtidos com a aplicação dos respectivos testes, Shapiro-Wilk, DickerFuller e Kruskal-Wallis para a cidade do Recife/PE, no período de janeiro de 2009 a dezembro de 2018.

Recife	Testes		
	Shapiro-Wilk	Dicker-Fuller Aumentado	Kruskal-Wallis
Estimativas	0,95	-6,74	41,72
p-valor	<0,01	<0,01	0,075

Fonte: Elaborada pelos Autores (2020).

A Figura 2 apresenta os gráficos *LAGs* da série temporal da radiação em Recife, onde o ponto corresponde ao valor da série temporal no tempo t versus o valor no tempo $t-1$, $t-2$, $t-3$ e $t-4$, usados para exibir eventuais correlações entre valores consecutivos. Ao observar os gráficos dos atrasos (Figura 2), o primeiro atraso mostra padrão linear e correlação alta, conforme Hopkins (2000), o que sugere que os dados não são verdadeiramente aleatórios e podem ser ajustados com o modelo AR. As defasagens mais altas não exibem um padrão linear, sugerindo que não estão correlacionadas. Embora não exista evidência de um padrão linear claro para os demais *lags*, isso não implica que a estrutura temporal é completamente desordenada e aleatória.

Figura 2. Gráfico *LAGS* da série temporal da radiação em Recife/PE para t versus o valor no tempo $t-1$, $t-2$, $t-3$ e $t-4$, no período de janeiro de 2009 a dezembro de 2018.



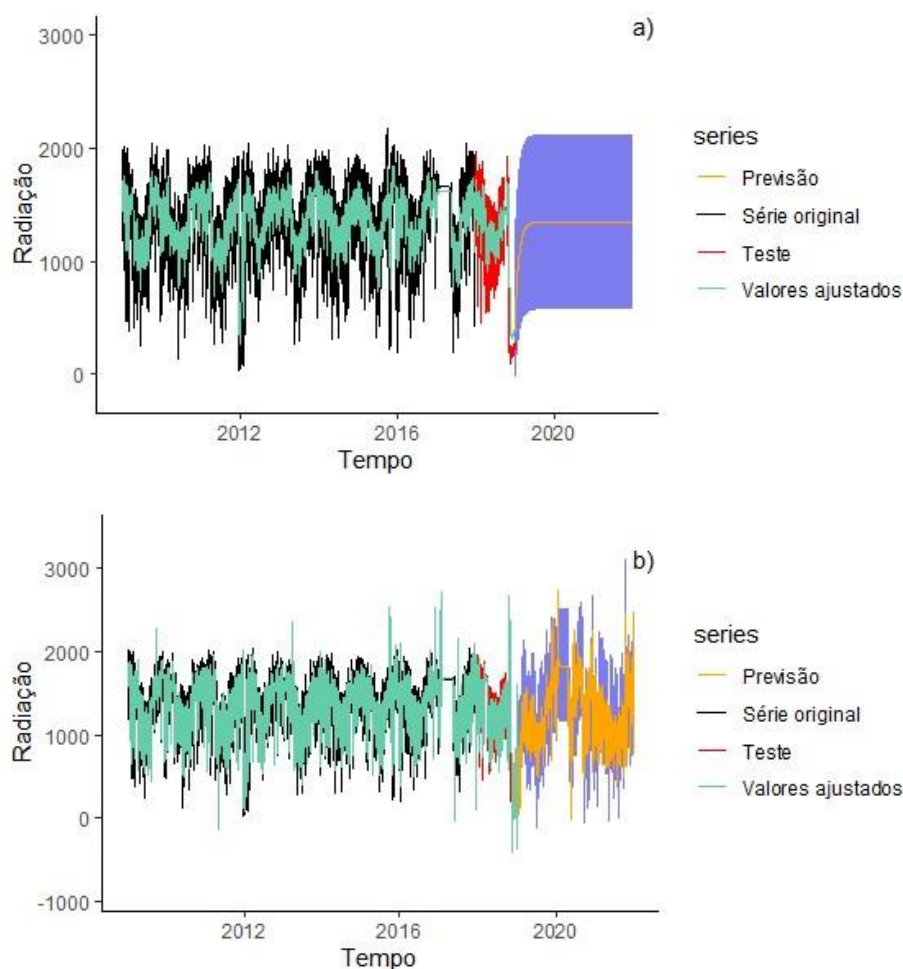
Fonte: Elaborado pelos autores (2020).

Através das abordagens, considerando os modelos ARMA e ARMAX (Figura 3) verifica-se que o modelo que melhor se adapta é o ARMAX (2,1), que captura a dinâmica do fenômeno que periodicamente cresce e decresce apesar de não ter se encontrado característica sazonal significativa ao nível de 5% de significância. A Figura 3 exibe os resultados dessa previsão com um intervalo de janelas abrangendo 1095 pontos de dados de predição e o conjunto de dados de previsão inteiro o modelo ARMAX fornece uma previsão muito boa do conjunto de dados especialmente durante eventos de previsibilidade esperados e para o conjunto teste, em relação ao modelo ARMA. A característica não linear da radiação torna mais difícil encontrar um modelo que capture este comportamento. Neste sentido, Baierle et al. (2019) utilizaram o método de mínimos quadrados com grau polinomial diferente para realizar o ajuste.

Os modelos de series temporais vêm sendo empregados em diversas áreas do

conhecimento, com a finalidade de prever fenômenos meteorológicos extremos, bem como uma possível ferramenta no estudo do potencial de geração de energia solar de uma região. Alsharif, Younes e Kim (2019) utilizaram o modelo SARIMA para previsão da radiação solar global média diária e mensal em Seul, Coreia do Sul, com o intuito de realizar um planejamento sustentável e adequado, especialmente no campo da geração de energia solar (Mo & Jeon, 2017). Com este mesmo intuito, para a cidade do Recife, PE, o presente trabalho tem por objetivo apresentar uma comparação do desempenho das classes de modelos de séries temporais ARMA e ARMAX, que trata-se de uma extensão do modelo anterior incluindo o efeito de variáveis exógenas, para melhor modelar a variável e de forma a buscar-se diminuir os erros de previsão.

Figura 3. Modelagem utilizando os Modelos ARMA (a) e ARMAX (b) da série temporal da Radiação em Recife/PE, no período de janeiro de 2009 a dezembro de 2018.



Fonte: Elaborada pelos Autores (2020).

Com base nos resultados dos experimentos, é possível analisar qual o melhor modelo

(ARMA e ARMAX) que pode ser usado para prever a radiação em Recife/PE. A seleção do melhor modelo pode ser feita a partir das medidas de eficiência e bondade do ajuste, como apresentado na Tabela 2. Observa-se que a utilização das modelagens com a inserção de variáveis exógenas proporciona melhores desempenhos para os ajustes aos dados observados em comparação aos outros modelos testados nesta pesquisa, isto é, a precisão de alguns critérios de valor com AIC, RMSE, MAE e MAPA produzidos pelo ARMAX tem valores menores em relação ao ARMA, indicando uma previsão mais precisa.

Tabela 2. Medidas comparativas de eficiência dos modelos de Séries Temporais para o município de Recife/PE, no período de janeiro de 2009 a dezembro de 2018.

Modelos	Medidas de Eficiências			
	AIC	RMSE	MAE	MAPE (%)
ARMA	51759,99	290,02	223,42	28,05
ARMAX	49180,45	203,34	148,59	18,68

Fonte: Elaborado pelos autores (2020).

4. Considerações Finais

O modelo ARMAX tem melhor desempenho que o ARMA visto que na comparação dos critérios, o AIC, RMSE, MAE e MAPE do ARMAX é menor que o ARMA, apresentando que a inclusão de variáveis exógenas pode gerar resultados mais precisos no estudo da radiação. Portanto, os modelos ARMAX possuem a capacidade de fazer predição com boa acurácia no estudo da radiação na cidade Recife/PE, como também sendo uma boa ferramenta para auxiliar o direcionamento de políticas de saúde pública incentivando ainda mais a utilização de protetores solares naquelas épocas em que o quantitativo de horas de insolação fosse maior e no planejamento sustentável.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) – Código de Financiamento 001. À Universidade Federal Rural de Pernambuco (UFRPE); ao Programa de Pós-Graduação em Biometria e Estatística Aplicada (PPGBEA) e Instituto Nacional de Meteorologia (INMET).

Referências

Akaike, H. (1974). A new look at the statistical model identification. *IEEE transactions on automatic control*, 19(6), 716-723. <https://doi.org/10.1109/TAC.1974.1100705>.

Alsharif, M. H., Younes, M. K., & Kim, J. (2019). Time series ARIMA model for prediction of daily and monthly average global solar radiation: The case study of Seoul, South Korea. *Symmetry*, 11(2), 240. <https://doi.org/10.3390/sym11020240>.

Baierle, E., Martins, M. T. F., Rodrigues, M. B., & Blass, L. (2019). Estudo da curva de radiação solar no município de Bagé utilizando métodos numéricos. *Anais do Salão Internacional de Ensino, Pesquisa e Extensão*, 10(2).

Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons, p. 709.

da Silva, C. A. G. (2019). Análise da previsão do preço do etanol hidratado no estado de São Paulo: uma aplicação do modelo arima/Analysis of the forecasting of the hydrated ethanol price in the state of São Paulo: an application of the arima model *Brazilian Journal of Development*, 5(10), 17763-17778. <https://doi.org/10.34117/bjdv5n10-045>.

da Silva Tabosa, F. J., Costa, E. M., do Amaral Filho, J., Neto, N. T., Araújo, J. A., & dos Santos, C. P. B. (2019). Análise da demanda por energia elétrica no meio rural do Brasil. *Planejamento e Políticas Públicas*, (52).

de Souza, S. R., Maciel, M. D. N. M., de Assis Oliveira, F., & de Almeida Jesuíno, S. (2011). Dinâmica da paisagem na bacia hidrográfica do Rio Apeú, nordeste do Pará, Brasil. *Revista Acadêmica Ciências Animal*, 9(2), 141-150. <https://dx.doi.org/10.73213/cienciaanimal.v9i2.11756>.

de Souza, A., Ihaddadene, R., Haddadene, N., Oguntunde, P., Pavao, H. P. H., Fernandes, W., de Oliveira-Júnior, J. F., Soares, D. G., Pobocikova, I., Abreu, M. C., & dos Santos, C. M. (2019). Modeling of the Global Solar Radiation Series as a Function of Probability Distribution. *Open Science Journal of Statistics and Application*, 6(3), 35.

Gómez, J. M., Carlesso, F., Vieira, L. E., & Da Silva, L. (2018). A irradiância solar: conceitos básicos. *Revista Brasileira de Ensino de Física*, 40(3). <https://doi.org/10.1590/1806-9126-rbef-2017-0342>.

Gujarati, D. N.; Porter, D. C. (2011). *Econometria Básica-5*. Amgh Editora, p. 918.

Handoyo, S., Efendi, A., Jie, F., & Widodo, A. (2017). Implementation of particle swarm optimization (PSO) algorithm for estimating parameter of arma model via maximum likelihood method. *Far East Journal of Mathematical Sciences*, 102(7), 1337-1363. <http://dx.doi.org/10.17654/MS102071337>.

Hopkins, W. G. Correlation coefficient: a new view of statistics. Recuperado de www.sportsci.org/resource/stats/correl.html, 2000.

Kruskal, W. H., & Wallis, W. A. (1952). Use of ranks in one-criterion variance analysis. *Journal of the American statistical Association*, Taylor & Francis Group, 47(260), 583-621. <https://doi.org/10.2307/2280779>.

Mo, J. Y., & Jeon, W. (2017). How does energy storage increase the efficiency of an electricity market with integrated wind and solar power generation? A case study of Korea. *Sustainability*, 9(10), 1797. <https://doi.org/10.3390/su9101797>.

Morettin, P. A., & Toloi, C. (2004). *Análise de Series Temporais*. São Paulo: Edgard Blucher LTDA, p. 535.

Peng, B. I., Xiao-Ming, S. H. I., & Qi-Yong, L. I. U. (2020). Climate change and population health research in China: Knowledge gaps and further directions. *Advances in Climate Change Research*.

Provenza, M. M., da Serra Costa, J. F., & de Carvalho Silva, L. (2018). Análise de dados e previsão de séries temporais do homicídio doloso no Estado do Rio de Janeiro entre 2001 e 2016. *Produção em Foco*, 8(2). <https://doi.org/10.14521/P2237-5163.2018.0015.0001>.

Rocha, C. A. (2017). Índice de qualidade ambiental de áreas utilizadas para a prática de atividades físicas e lazer na cidade de Fortaleza, CE.

Santos, D. A. D. S., Azevedo, P. V. D., Olinda, R. A. D., Santos, C. A. C. D., Souza, A. D., Sette, D. M., & Souza, P. M. D. (2017). A relação das variáveis climáticas na prevalência de infecção respiratória aguda em crianças menores de dois anos em Rondonópolis-MT, Brasil. *Ciência & saúde coletiva*, 22, 3711-3722. <https://doi.org/10.1590/1413-812320172211.28322015>.

Shapiro, S. S., & Wilk, M. B. (1965). An analysis of variance test for normality (complete samples). *Biometrika*, 52(3/4), 591-611, 1965. <https://doi.org/10.2307/2333709>.

Spokas, K., & Forcella, F. (2006). Estimating hourly incoming solar radiation from limited meteorological data. *Weed science*, 54(1), 182-189. <https://doi.org/10.1614/WS-05-098R.1>.

Sobral, M. F. F., Duarte, G. B., da Penha Sobral, A. I. G., Marinho, M. L. M., & de Souza Melo, A. (2020). Association between climate variables and global transmission of SARS-CoV-2. *Science of The Total Environment*, 729, 138997.

Souza, A. D., Andrade, F. A., Oguntunde, P. E., Arsić, M., & Silva, D. A. (2018). Climate indicators and the impact on morbidity and mortality of acute respiratory infections. *Advanced Studies in Medical Sciences*, 6(1), 5-20.

Tawatsupa, B., Lim, L. L., Kjellstrom, T., Seubsman, S. A., Sleigh, A., & Thai Cohort Study Team. (2012). Association between occupational heat stress and kidney disease among 37 816 workers in the Thai Cohort Study (TCS). *Journal of epidemiology*, 22(3), 251-260. <https://doi.org/10.2188/jea.JE20110082>.

Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate research*, 30(1), 79-82.

Porcentagem de contribuição de cada autor no manuscrito

Jucarlos Rufino de Freitas – 18%

Ruben Vivaldi Silva Pessoa – 18%

Mickaelle Maria de Almeida Pereira – 18%

Leika Irabele Tenório de Santana – 18%

Joelma Mayara da Silva – 18%

Moacyr Cunha Filho – 10%