

Eixo Temático ET-06-012 - Energia

PREVISÃO DOS NÍVEIS DE RADIAÇÃO SOLAR GLOBAL PARA O MUNICÍPIO DE JOÃO PESSOA

Luiz Moreira Coelho Junior¹, Thiago Freire Melquiades², Filipe Vanderlei Alencar³,
Levi Pedro Barbosa de Oliveira¹

¹Universidade Federal da Paraíba – UFPB/João Pessoa, Departamento de Engenharia de Energias Renováveis, Paraíba, Brasil; ²Universidade Federal da Paraíba – UFPB/João Pessoa, Programa de Pós-Graduação em Energias Renováveis, Paraíba, Brasil; ³Universidade Federal da Paraíba – UFPB/João Pessoa, Engenharia de Energias Renováveis, Paraíba, Brasil.

RESUMO

O aproveitamento da energia solar pode ser uma alternativa ao uso dos combustíveis fósseis, apesar do seu pouco uso no Brasil. Apenas 15 MW da capacidade instalada para a geração de energia elétrica é proveniente da energia solar. Entre os 27 estados do Brasil, apenas Ceará, Rio Grande do Norte, Pernambuco, Bahia, Minas Gerais, Rio de Janeiro, São Paulo e Santa Catarina, apresentam geração de energia elétrica por aproveitamento da energia solar. Portanto, apesar da pouca participação de fontes alternativas na matriz energética brasileira, o uso da energia solar ainda significa um desafio para o País. À vista disto, este trabalho analisou a Série de Radiação Solar Global, no período de julho de 2007 a dezembro de 2013 no município de João Pessoa, na Paraíba, por meio dos modelos da família ARIMA e testando os modelos estimados na previsão de 2014. O método utilizado foi preconizado por Box e Jenkins na década de 70, por meio dos modelos da família ARIMA. Para a análise da série e a escolha do modelo para previsões do ano de 2014, foi usada como base a análise residual do teste de *Ljung-box statistic*, *box-pierce*, o *Akaike Information Criterion* (AIC) e Erro Quadrático Médio de Previsão como fonte de seleção dos modelos. O modelo SARIMA (2,1,0) (2,1,3)₁₂ foi o que forneceu melhor ajuste na previsão para 12 períodos da radiação solar global para 2014 do município de João Pessoa, dentro de um intervalo de 95% de confiança.

Palavras-chave: Radiação solar; Séries temporais; Modelo Box-Jenkins.

INTRODUÇÃO

O aproveitamento da energia solar é uma alternativa ao uso dos combustíveis fósseis, apesar de ser pouco usual no Brasil. Segundo a Empresa de Pesquisa Energética – EPE (2015), em 2014, de toda a oferta interna de energia elétrica do Brasil, 65,2% eram oriundos de fontes hidráulicas, seguidos por 13% de gás natural, 7,3% de biomassa, 6,9% de derivados do petróleo, 3,2% de carvão e derivados, 2,5% de energia nuclear e 2% de energia eólica. Do total de 133.913 MW de capacidade instalados para geração de energia elétrica, apenas 15 MW eram provenientes da energia solar.

No Brasil, apenas os estados do Ceará, Rio Grande do Norte, Pernambuco, Bahia, Minas Gerais, Rio de Janeiro, São Paulo e Santa Catarina geram energia elétrica por aproveitamento da energia solar. Apesar da pouca participação na matriz energética brasileira, o uso da energia solar ainda significa um desafio para o País (EPE, 2015).

Em busca de entender o comportamento da incidência solar sobre a Terra, como, por exemplo, a radiação, é necessário o uso de estações meteorológicas. Um controle preciso e o acompanhamento das volatilidades a respeito da energia solar auxiliam o fornecimento de resultados determinantes para o melhor aproveitamento da energia solar em uma determinada região. Para tal, são utilizadas algumas técnicas de modelagem de previsão em séries temporais. Esses métodos consideram seus resultados dentro de uma determinada margem de confiança.

Uma metodologia bastante utilizada foi desenvolvida por Box e Jenkins (1976) na década de 70, com a publicação do livro *Time Series Analysis, Forecasting and Control*. Essa abordagem é conhecida como box-jenkins, e estuda como o comportamento de uma série temporal pode ser essencialmente definido pelo seu próprio comportamento no passado.

A aplicação da metodologia box-jenkins para os níveis de radiação solar global foi utilizada por Yürekli et al. (2007), Reikard (2009), Hejase e Assi (2012), Huang et al. (2012), Ferrari et al. (2013), Hassan (2014), Sun et al. (2015). Esses estudos analisaram os resultados obtidos entre os diversos modelos de previsão. Desta forma, as modelagens envolvendo a radiação solar podem determinar questões relevantes para as regiões do Brasil com baixo aproveitamento da energia solar, como o estado da Paraíba.

À vista disto, este artigo analisou a Série de Radiação Solar Global, no período de julho de 2007 a dezembro de 2013 do município de João Pessoa, na Paraíba, por meio dos modelos da família ARIMA e testou os modelos estimados na previsão de 2014.

OBEJTIVO

Este artigo analisou a Série de Radiação Solar Global, no período de julho de 2007 a dezembro de 2013 do município de João Pessoa, na Paraíba, por meio dos modelos da família ARIMA e testou os modelos estimados na previsão de 2014.

MATERIAL E MÉTODOS

Objeto de Estudo

Os dados utilizados foram obtidos junto ao Instituto Nacional de Meteorologia – INMET e são referentes ao nível de radiação solar global em kJ/m² do município de João Pessoa, na Paraíba. Os dados são do monitoramento da estação meteorológica de superfície automática A320, desde o início de suas operações (BRASIL, 2015).

O período utilizado abrangeu de 22 de julho de 2007 a 31 de setembro de 2015. A série temporal analisada corresponde a 38.909 observações, sendo que as informações são atualizadas a cada hora pela estação meteorológica de superfície automática. Desta forma, foram definidos os horários de observação das 6 horas às 18 horas, fornecendo 2.993 observações a cada hora.

Os dados coletados a cada hora por dia foram transformados para valores mensais. Foram somados os valores apresentados a cada hora (6h às 18h) para o fornecimento dos dados de radiação solar global diários e em seguida, foi feita a média diária de cada mês. Os dados foram convertidos de kJ/m² para kWh/m². Para fazer a previsão, foi reservado o ano de 2014 no intuito de fazer a validação do modelo ajustado.

Metodologia Box-Jenkins

Um método de seleção de modelos para séries temporais foi desenvolvido na década de 1970 pelos Professores George E. P. Box e Gwilym M. Jenkins. Essa técnica consiste nas seguintes etapas: determinação da classe do modelo; identificação do modelo proposto por meio da Função de Autocorrelação (FAC) e da Função de Autocorrelação Parcial (FACP) e outros critérios; determinação dos parâmetros do modelo na qual foi identificado; diagnóstico do modelo ajustado, averiguando se os resíduos são ruído branco e adequados para previsão. Caso o modelo se apresente adequado, o processo é finalizado e ocorre a previsão, caso contrário, o processo é reiniciado a partir da etapa de identificação (MORETTIN e TOLOI, 2006). A estrutura que representa esse processo é demonstrada na Figura 1.




Figura 1. Metodologia Box-Jenkins. Fonte: Morettin; Tolo (2006).

Os modelos Autoregressivos (AR) de Médias Móveis (MA) partem da combinação dos processos AR e MA denominados *ARMA* (p, q), como está sendo descrito na equação 1. Onde $\phi_p(B)$ representa o operador AR (p), z_t é a série temporal observada, $\theta_q(B)$ consiste no operador MA (q) e α_t , o choque aleatório numa distribuição normal com zero de média e variância no tempo.

$$\phi_p(B)z_t = \theta_q(B)\alpha_t \quad (1)$$

O processo de seleção dos modelos por meio da metodologia box-jenkins é iniciado o com a identificação dos parâmetros AR e MA da série temporal. No entanto, os processos *AR* (p), *MA* (q) e *ARMA* (p, q) são estacionários. No caso de processos não estacionários, é necessário que seja feita a diferenciação para torná-los estacionários, então é acrescentado o parâmetro d , formando o *ARIMA* (p, d, q) como exposto na equação 2. A equação $\Delta^d z_t = (1 - B)^d z_t$, refere-se à ordem de diferenciação (LEE; KO, 2011).

$$\phi_p(B)\Delta^d Z_t = \theta(B)\alpha_t \quad (2)$$

Para modelos com a presença de sazonalidade de uma série temporal deve ser acrescentado um “S”. Assim, chegando ao *SARIMA* (p, d, q)(P, D, Q) $_s$, que representa o modelo ARIMA sazonal multiplicativo (3). A equação $\Delta_S^D Z_t = (1 - B^S)^D z_t$ diz respeito à ordem de diferenciação sazonal, sendo definida pelo parâmetro D . O $\Phi_p(B^S)$ representa *AR* (p) sazonal e $\Theta_Q(B^S)$, o *MA* (q) sazonal, esses são definidos nas equações 4 e 5, respectivamente. Os parâmetros sazonais de *AR* (p) são descritos por $\Phi_1 \dots \Phi_p$, já *MA* (q) por $\Theta_1 \dots \Theta_Q$ (LEE e KO, 2011).

$$\phi_p(B)\Phi_p(B^S)\Delta^d \Delta_S^D Z_t = \theta_q(B)\Theta_Q(B^S)\alpha_t \quad (3)$$

$$\Phi_p(B^S) = 1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_p B^{pS} \quad (4)$$

$$\Theta_Q(B^S) = 1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS} \quad (5)$$

Segundo Gujarati (2006), a Função de Autocorrelação (FAC) é dada por k defasagens, com denotação de ρ_k (6). O termo γ_k representa a covariância com k defasagens e γ_0 representa a variância, caracterizando que quando a defasagem $k = 0$, temos que $\rho_0 = 1$, considerando que ρ_k é um número puro que se situa entre ± 1 para qualquer coeficiente de correlação. A Função de Autocorrelação (FAC) denota a autocorrelação *versus* as defasagens, e auxilia a identificação do processo de Médias Móveis de Ordem q – *MA* (q), tendo uma participação bastante importante na estimação de séries temporais. Considerando a equação 10, em que ε_t representa ruído

branco, e y_t depende do erro ε_t , seguidamente do erro do passado, temos um processo denominado Médias Móveis de Ordem 1 – *MA (1)*, no entanto, se o processo depende de ε_{t-2} , passamos a chamá-lo de Médias Móveis de Ordem 2 – *MA (2)*. Já a Função de Autocorrelação Parcial (FACP), é caracterizada por um processo de filtragem da FAC, demonstrado por um Processo Autorregressivo de Ordem p – *AR (p)*, ou seja, temos um processo de filtragem, no qual são excluídas as correlações implícitas, conservando as relações puras entre as observações. A FACP denota $\hat{\phi}_{j,j}$, versus j , onde se extrai a regressão de y_t em detrimento de y_{t-1} , obtendo $\phi_{1,1}$, e, por conseguinte, y_t versus y_{t-1} e y_{t-2} , assim conseguimos $\phi_{2,1}$ $\phi_{2,2}$, como mostra a equação 11 (BUENO, 2011).

$$y_t = \mu + \varepsilon_t + \theta\varepsilon_{t-1} \tag{10}$$

$$y_t = \varphi_{j,1}y_{t-1} + \varphi_{j,2}y_{t-2} + \dots + \varphi_{j,j}y_{t-j} + e_{t,j} = 1, 2, \dots \tag{11}$$

Para a comprovação formal da estacionariedade de uma série temporal, é necessária a consulta a alguns testes, como, por exemplo, o teste *Dickey-Fuller* Aumentado (ADF), desenvolvido por Dickey e Fuller (1981), o teste *Phillips-Perron* (PP); desenvolvido por Phillips e Perron (1988) e o teste *Kwiatkowski-Phillips-Schmidt-Shin* (KPSS); desenvolvido por Kwiatkowski e outros (1992). Esses testes confirmam se a série Y_t possui ou não raiz unitária, com isso, podendo ser comprovada ou não a sua estacionariedade.

Após identificação dos parâmetros da série, ela pode ser representada por um modelo ARIMA (p,d,q) ou SARIMA (p,d,q)(P,D,Q)_s caso haja indícios de sazonalidade. O processo parte para verificação das funções de autocorrelação (FAC) e autocorrelação parcial (FACP), assim como os testes ADF, PP e KPSS, para verificação da raiz unitária da série. Logo após, são escolhidos os modelos pretendentes utilizando o *Akaike Information Criterion* (AIC), seguindo o princípio da parcimônia, então é feita a análise dos resíduos da série ajustada, verificando a existência de ruído branco.

Na interpretação de Bueno (2011), os critérios de informação são importantes para balancear a redução do erro, fornecendo os parâmetros aceitáveis para um modelo, como exposto na equação 14.

$$AIC(p, q) = \ln \hat{\sigma}^2 + n \frac{2}{T} \tag{14}$$

O *Portmanteau Test*, de acordo com Tsay (2005), pode ser definido pela equação 15, em que é rejeitada a hipótese de H_0 se $Q(m) > x_\alpha^2$. A análise permite reforçar a existência de ruído branco no modelo escolhido por meio da verificação dos resíduos. Em outras palavras, a constatação de ruído branco pelo teste *box-pierce* ocorre quando onde $Q(m) < \chi_\alpha^2$, isso que não há quebra de comportamento de ruído branco.

$$Q(m) = T(T+2) \sum_{i=1}^m \frac{\hat{\rho}_i^2}{T-1} \tag{15}$$

Foi verificado o Erro Quadrático Médio (EQM) das previsões obtidas, permitindo a comparação dos valores previstos e observados da série ajustada (16), sendo escolhido possibilitando a escolha do modelo que apresentar o menor EQM (MORETTIN e TOLOI, 2006).

$$EQM = \frac{\sum (y_t - y_t^e)^2}{n} \quad (16)$$

RESULTADOS E DISCUSSÃO

A Figura 2 apresenta o comportamento dos valores médios da Série em nível (original) da Radiação Solar Global (SRSG), sendo a série logaritmizada definida por $[\text{Ln}(\text{SRSG})]$ em kWh/m² no período de julho de 2007 a dezembro de 2013. A SRSG em nível possui média estimada em 5,82, mediana de 5,89, variância de 0,48, valor mínimo de 4,29 e valor máximo de 7,02. A logaritmização neperiana foi necessária para estabilização da variância, preservando as propriedades dos dados da série. A variância da série foi de 0,002.




Figura 2. Série em Nível (original) da Radiação Solar Global em Nível e Logarítmica de Julho de 2007 a Dezembro de 2013 em kWh/m². Fonte: Elaboração própria.

A análise visual da SRSG e $\text{Ln}(\text{SRSG})$ não apresenta nenhuma tendência ao longo do tempo, fornecendo indícios de que ela pode ser estacionária. A Figura 3 expõe a FAC para o $\text{Ln}(\text{SRSG})$ em nível (3.a) e em primeira diferença (3.b), além da FACP em nível (3.c) em primeira diferença (3.d). Verificou-se que a FAC e FACP em nível apresentam *lags* que decaem rapidamente, isso indica a possibilidade de a série temporal ser estacionária. Para verificar a existência de sazonalidade, foi necessário fazer a primeira diferenciação do $\text{Ln}(\text{SRSG})$. A FAC em primeira diferença demonstra *lags* significativos a cada 12 passos à frente, fornecendo indícios de que o $\text{Ln}(\text{SRSG})$ pode apresentar o componente sazonal. No entanto, foi feita a decomposição da série para uma posterior constatação.

Foi delimitada a ordem de no máximo 3 defasagens para o modelo em processos autoregressivos $[\text{AR} (p = 3 \text{ e } P = 3)]$ e de 3 defasagens para os processos de médias móveis $[\text{MA} (q = 3 \text{ e } Q = 3)]$, seguindo o princípio da parcimônia. Foi constituído um espaço amostral de 324 modelos SARIMA $(p,d,q) (P,D,Q)_{12}$, dentre os quais foi utilizado o *Akaike Information Criterion (AIC)* como fonte de seleção dos modelos, além da análise residual do teste de *Ljung-box statistic e box-pierce*.

A identificação dos parâmetros AR e MA, de acordo com Meyler (1998), pode ser realizada por meio da interpretação dos gráficos de Autocorrelação (FAC) e Autocorrelação Parcial (FACP), esse processo pode ser difícil e a identificação dos modelos por meio da metodologia box-Jenkins envolve certa subjetividade.

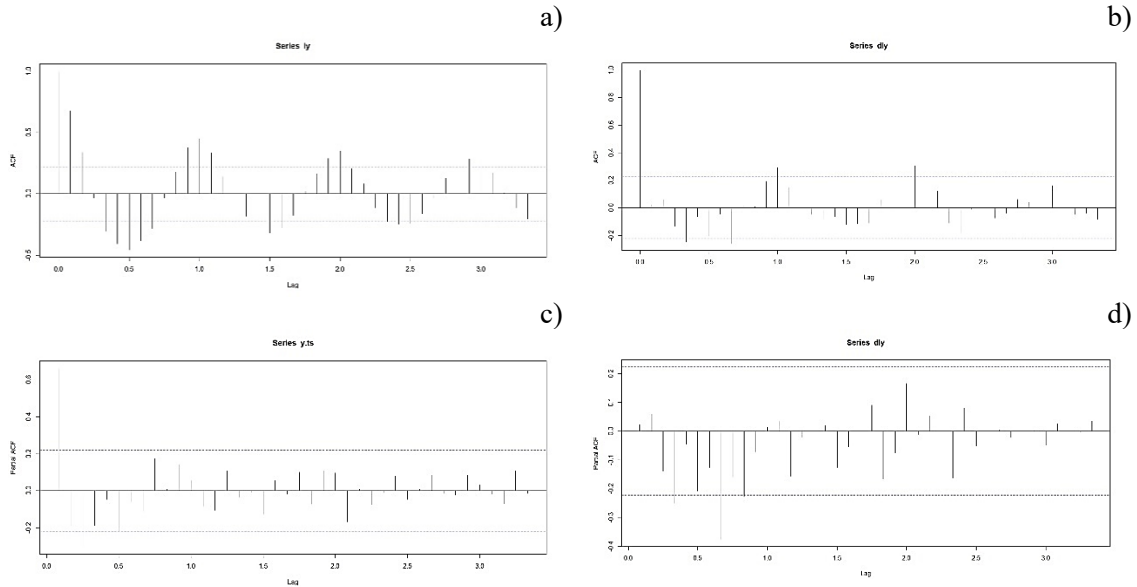


Figura 3. Função de Autocorrelação (FAC) da Ln (SRSG) em nível (a), Primeira Diferença (b). Função de Autocorrelação Parcial (FACP) da Ln (SRSG) em Nível (c) e em Primeira Diferença (d). Fonte: Elaboração própria.

A Figura 4 apresenta os efeitos sobre a variação nos dados, tendência, sazonalidade e resíduos do Ln (SRSG). Foi verificado por meio da decomposição da série temporal que a variação dos dados é o componente com maior destaque. Em seguida, vem o comportamento dos resíduos; indicado pelas flutuações estocásticas, presença de sazonalidade e tendência. As maiores características são expostas pelo tamanho das barras cinza, quanto menores elas forem, mais predominante é o componente, quanto maior, menos predominante é o componente da decomposição do Ln (SRSG). Apenas com a verificação visual e da decomposição da série não se pode afirmar se a série Ln (SRSG) é estacionária ou não. Para uma constatação formal, foram utilizados os testes *Dickey-Fuller* Aumentado (ADF), o teste *Phillips-Perron* (PP) e o teste *Kwiatkowski-Phillips-Schmidt-Shin* (KPSS), para verificação da presença de raiz unitária, como exposto na Tabela 1.




Figura 4. Decomposição da SRS.

O teste ADF mostra a presença da estacionariedade quando há rejeição da hipótese nula (H_0), ou seja, quando a série tem presença de raiz unitária. E para a hipótese alternativa (H_1) é a constatação da estacionariedade da série, não incorrendo na região de raiz unitária. O teste ADF rejeita H_0 para a $\text{Ln}(\text{SRS})$ nível, já que $t = -5,189$ é maior do que todos os valores críticos para os níveis de significância de 1%, 5% e 10%, pois não há presença de raiz unitária, ou seja, $\text{Ln}(\text{SRS})$ é estacionária. Aplicando o teste ADF à 1ª diferença da $\text{Ln}(\text{SRS})$, foi possível observar que $t = -5,622$, acima de todos os níveis de significâncias estudados. A $\text{Ln}(\text{SRS})$ já é estacionária em nível. O teste KPSS afirma que a hipótese nula é a não existência de raiz unitária, a $\text{Ln}(\text{SRS})$ em nível apresentou $t = 0,145$, sendo menor do que todos os valores críticos do teste. Isso aceita H_0 , ou seja, a $\text{Ln}(\text{SRS})$ em nível é estacionária. Em primeira diferença, $t = 0,028$, menor do que o valor inicial e do que todos os níveis críticos, mas, a estacionariedade foi comprovada para a $\text{Ln}(\text{SRS})$ em nível no teste. O teste PP tanto para a $\text{Ln}(\text{SRS})$ em nível quanto para a 1ª Dif [$\text{Ln}(\text{SRS})$], comprova a estacionariedade, demonstrando $t = -3,820$ e $t = -8,45$, acima de qualquer valor crítico do teste.

Do espaço amostral constituído por 324 modelos, foi selecionada uma amostra dos 30 modelos que apresentaram AIC. Estes modelos, inicialmente, apresentaram auto correlação residual por meio do teste *Ljung-box statistic*, sendo excluídos. Desta forma, prosseguiu-se com a seleção, utilizando o teste AIC, teste *box-pierce* para $K - 3$ graus de liberdade e $Q(10)$ e *Ljung-box statistic*. Apenas 30 modelos atenderam aos três critérios, não apresentaram autocorrelação residual, sendo considerados ruído branco para o teste *Ljung-box statistic* e *box-pierce*, desta forma, foram separados para realização das previsões.

Após a filtragem por meio do AIC, *Ljung-box statistic* e *box-pierce*, apenas 19 modelos apresentaram valores significativos a um nível de significância de 95%. A Tabela 2 demonstra os 5 modelos que obtiveram os melhores EQM das previsões. Além dos respectivos AIC e teste *box-pierce*.

Tabela 1. Testes de Raiz Unitária da $\text{Ln}(\text{SRS})$ Nível e Primeira Diferença (1ª Dif [$\text{Ln}(\text{SRS})$]).

Testes	$\text{Ln}(\text{SRS})$				1ª Dif [$\text{Ln}(\text{SRS})$]			
	1%	5%	10%	t	1%	5%	10%	t
ADF	-3,510	-2,890	-2,580	-5,189	-3,510	-2,890	-2,580	-5,622
KPSS Test	0,739	0,463	0,347	0,145	0,739	0,463	0,347	0,028
Phillips-Perron	-3,516	-2,899	-2,587	-3,820	-3,516	-2,899	-2,587	-8,453

Tabela 2. Modelos Pré-Selecionados.

	SARIMA (p,d,q)(P,D,Q) ₁₂	EQM	AIC	Test box-pierce	
				Q (10)	$\chi^2_{7;0,05}$
1	(2,1,0) (2,1,2) ₁₂	0,46	-114,07	0,075	8,486
2	(2,1,0) (2,1,3) ₁₂	0,44	-112,69	0,039	8,338
3	(3,1,0) (0,0,2) ₁₂	0,62	-139,93	0,078	9,894
4	(0,1,1) (2,1,3) ₁₂	0,47	-115,08	0,058	9,114
5	(1,1,2) (0,0,2) ₁₂	0,61	-138,55	0,091	9,462

Com essa análise, a Tabela 3 mostra a previsão realizada para o modelo SARIMA (2,1,0) (2,1,3)₁₂, já que este apresentou o menor EQMP. As previsões de radiação global mensal em kWh/m² foram realizadas para o ano de 2014.

Sendo o modelo SARIMA (2,1,0) (2,1,3)₁₂ escolhido, a sua forma é demonstrada pela equação 17. Logo, o modelo com seus coeficientes assume a expressão da equação 18.

$$Y_t = \frac{(1 - \Theta_1 B^{12} - \Theta_2 B^{24} - \Theta_3 B^{36}) \alpha_t}{(1 - \phi_1 B - \phi_2 B^2)(1 - \Phi_1 B^{12} - \Phi_2 B^{24})(1 - B)(1 - B^{12})} \quad (17)$$

$$Y_t = \frac{(1 + 0,60B^{12} + 0,90B^{24} - 0,52B^{36}) \alpha_t}{(1 + 0,27B - 0,02B^2)(1 + 0,48B^{12} - 0,29B^{24})(1 - B)(1 - B^{12})} \quad (18)$$

Tabela 3. Valores Observados e Previsões pelos Modelos SARIMA (2,1,0) (2,1,3)₁₂ para 2014.

Período	Observado	(2,1,0) (2,1,3) ₁₂	Acerto (%)
jan/14	6,65	6,15	-7,6%
fev/14	6,27	6,13	-2,2%
mar/14	6,58	6,50	-1,2%
abr/14	6,19	5,49	-11,3%
mai/14	5,19	5,16	-0,5%
jun/14	4,83	5,02	3,9%
jul/14	5,15	5,12	-0,6%
ago/14	5,94	6,06	1,9%
set/14	5,88	6,12	4,1%
out/14	6,42	6,64	3,4%
nov/14	6,25	6,70	7,1%
dez/14	4,44	6,48	45,8%
Somatório	69,86	71,62	2,5%
Média	5,82	5,96	2,5%
EQM		0,44	

Fonte: Elaboração própria.

A Figura 5 apresenta os valores residuais do modelo SARIMA (2,1,0) (2,1,3)₁₂. O correlograma do teste *Ljung-box statistic* sugere independência dos resíduos para diversas defasagens, ou seja, não demonstrando autocorrelação.




Figura 5. Resíduos do Modelo SARIMA $(2,1,0) (2,1,3)_{12}$ para a SRSg. Fonte: Elaboração própria.

A Figura 6 demonstra o comportamento da previsão da radiação solar global em kWh/m² para a cidade de João Pessoa, considerando um intervalo de confiança de 95%, além dos valores observados para o ano de 2014 em meses.

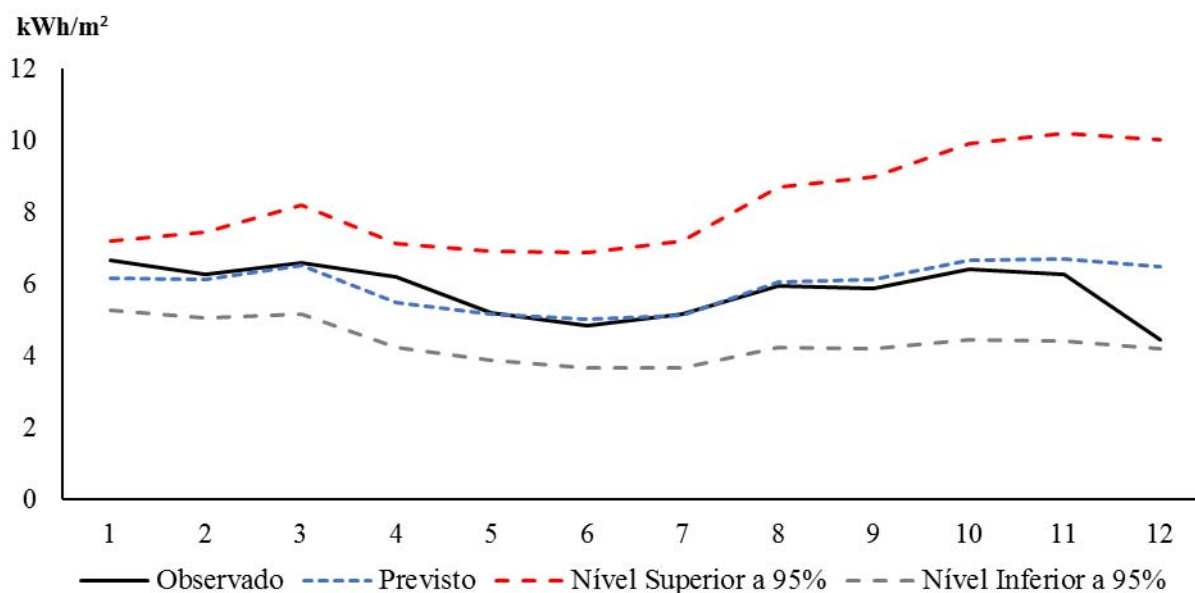


Figura 6. Previsão para o Ano de 2014 da Radiação Solar Global em João Pessoa (kWh/m²). Fonte: Elaboração própria.

CONCLUSÃO

Para os resultados obtidos por este artigo, foi possível concluir que: Foi fornecida uma melhor compreensão a respeito do comportamento da série de radiação solar global em João Pessoa. Os dados da SRSg apresentaram comportamento estacionário ao longo do tempo, ou seja, sem tendência. Também apresentaram efeitos de sazonalidade anual. Os modelos da família ARIMA apresentaram resultados satisfatórios para a previsão. O modelo SARIMA $(2,1,0) (2,1,3)_{12}$ foi o que forneceu melhor ajuste da radiação solar global para 2014 do município de João Pessoa.

REFERÊNCIAS

- BOX, G; JENKINS, G. **Time series analysis: forecasting and control**. rev. ed. Oakland, California: Holden-Day, 1976.
- BRASIL. Ministério da Agricultura Pecuária e Abastecimento. **Instituto Nacional de Meteorologia (INMET)**. Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=estacoes/estacoesAutomaticas>>. Acesso em: 12 nov. 2015.
- BUENO, R. L. S. **Econometria de séries temporais**. São Paulo: Cengage Learning, 2011.
- DICKEY, D. A.; FULLER, W. A. Likelihood ratio statistics for autoregressive time series with a unit root. **Econometrica**, n. 49, p. 1057-1071, 1981.
- EPE - Empresa de Pesquisa Energética. **Balanco energético nacional 2015: ano base 2014**. Disponível em: <https://ben.epe.gov.br/downloads/Relatorio_Final_BEN_2015.pdf>. Acesso em: 15 nov. 2015.
- FERRARI, S. et al. Statistical models approach for solar radiation prediction. In: **Instrumentation and Measurement Technology Conference (I2MTC), 2013 IEEE International**. IEEE, 2013. p. 1734-1739.
- GUJARATI. D.N. **Econometria básica**. Rio de Janeiro: Elsevier, 2006.
- HASSAN, J. ARIMA and regression models for prediction of daily and monthly clearness index. **Renewable Energy**, v. 68, p. 421-427, 2014.
- HEJASE, H.; ASSI, A. Time-series regression model for prediction of mean daily global solar radiation in Al-Ain, UAE. **ISRN Renewable Energy**, v. 2012, 2012
- HUANG, R. et al. Solar Generation Prediction using the ARMA Model in a Laboratory-level Micro-grid. In: **Smart Grid Communications (SmartGridComm), 2012 IEEE Third International Conference on IEEE**, 2012. p. 528-533.
- KWIATKOWSKI, D.; PHILLIPS, P. C. B.; SCHMIDT, P.; SHIN, Y. Testing the null hypothesis of stationarity against the alternative of a unit root. **Journal of Econometrics**, v. 54, p. 159-178, 1992.
- LEE, C.; KO, C. Short-term load forecasting using lifting scheme and ARIMA models. **Expert Systems with Applications**, v. 38, n. 5, p. 5902-5911, 2011.
- MEYLER, A.; KENNY, G.; QUINN, T. **Forecasting Irish inflation using ARIMA models**. 1998.
- MORETTIN, P. A; TOLOI, C. M. C. **Análise de séries temporais**. São Paulo: Edgard Blucher, 2006.
- PHILLIPS, P. C. B.; PERRON, P. Testing for a unit root in time series regression. **Biometrika**, n. 75, p. 335-346, 1988.
- REIKARD, G. Predicting solar radiation at high resolutions: A comparison of time series forecasts. **Solar Energy**, v. 83, n. 3, p. 342-349, 2009.
- SUN, H. et al. Empirical investigation on modeling solar radiation series with ARMA-GARCH models. **Energy Conversion and Management**, v. 92, p. 385-395, 2015.
- TSAY, R. S. **Analysis of financial time series**. 2. ed. New Jersey: John Wiley, 2005.

WU, J.; CHAN, C. K. The Prediction of Monthly Average Solar Radiation with TDNN and ARIMA. In: **Machine Learning and Applications (ICMLA), 2012 11th International Conference on IEEE**, 2012. p. 469-474.

YÜREKLI, K. et al. Simulating climatic variables by using stochastic approach. **Building and environment**, v. 42, n. 10, p. 3493-3499, 2007.