

Previsão de Irradiação Solar em Sistemas Fotovoltaicos Usando Análise de Séries Temporais *

Matheus Pereira Gomes * Luciana Martinez *
Daniel Barbosa * Ângelo Sant'anna **

* Departamento de Engenharia Elétrica, Universidade Federal da Bahia, BA, (e-mail: elemat.eng@gmail.com; lucianam@ufba.br; dbarbosa@ufba.br).

** Departamento de Engenharia Mecânica, Universidade Federal da Bahia, BA, (e-mail: angelo.santanna@ufba.br)

Abstract: This work consists in the application of time series analysis to predict solar irradiation in photovoltaic generation systems. The importance of this type of forecasting is to favor the planning, operation and maintenance routine of these types of systems, as well as to serve the basis of feasibility studies and expansion of solar generation. Given a stochastic resource and the periodic behavior of solar irradiation data, a periodic autoregressive model was considered, statistics were used using the Maximum Likelihood method, based on hourly irradiation measurements over a period of one year. An end of analysis or prediction method performance were performed days after different solar irradiation intensities. The results obtained with a good performance of the automatic regressive periodic model in forecasting the estimated data.

Resumo: Esse trabalho consiste na aplicação da análise de séries temporais para a previsão de irradiação solar em sistemas de geração fotovoltaica. A importância deste tipo de previsão é favorecer o planejamento, a operação e a rotina de manutenção destes tipos de sistemas, assim como servir de base para estudos de viabilidade e expansão da geração solar. Devido à característica estocástica e o comportamento periódico dos dados de irradiação solar, um modelo periódico auto-regressivo foi considerado, cujos parâmetros foram ajustados utilizando-se o método da Máxima Verossimilhança, com base em medições horárias de irradiação, realizadas em um período de um ano. A fim de se analisar o desempenho do método de previsão, foram realizadas previsões de dias com diferentes intensidades de irradiação solar. Os resultados mostraram um bom desempenho do modelo periódico auto-regressivo na previsão dos dados considerados.

Keywords: Time Series; Self-regressive Periodic Model; Power generation; Photovoltaic; Maximum likelihood.

Palavras-chaves: Séries Temporais; Modelo Periódico Auto-Regressivo; Geração de Energia; Fotovoltaico; Máximo Verossimilhança.

1. INTRODUÇÃO

O processo de geração de energia elétrica diversificou-se ao longo dos anos e as fontes de geração mais utilizadas no sistema elétrico brasileiro, como as fontes de natureza hidráulica e térmica, compartilham esse cenário com outros tipos de fontes de geração, provenientes de diferentes tipos de recursos presentes na matriz energética brasileira (ANEEL (2008), Bondarik et al. (2018)).

Com o enrijecimento das leis ambientais, fontes de cunho renovável coadjuvarão, no futuro, com o objetivo de garantir a minimização dos efeitos deletérios dos diferentes processos de geração de energia elétrica. Conjuntamente com o viés ambiental, o caráter técnico e econômico deve

ser levado em consideração no planejamento da geração, na operação e na manutenção destes sistemas de geração de energia. Neste sentido, os maiores desafios estão pautados na implantação de decisões que sustentem todas essas perspectivas de maneira otimizada.

Grande parte dos recursos da matriz energética utilizados para geração de energia elétrica possuem características sazonais e/ou periódicas, associadas a elementos e fenômenos da natureza (Bondarik et al. (2018)). Com exceção dos casos de mudanças meteorológicas repentinas ou de tragédias naturais, esses fenômenos naturais possuem características e comportamentos passíveis de serem modelados e previstos com razoável precisão. Neste sentido, o planejamento de sistemas de geração de energia tem a previsão como grande aliada. Assim, com o auxílio de metodologia e ferramentas adequadas é possível se estimar

* Agradecimentos ao Conselho Nacional de Desenvolvimento Científico e Tecnológico(CNPq) pelo suporte financeiro

a quantidade de energia disponível para a geração elétrica futura.

Os sistemas de geração fotovoltaica possuem vantagens em relação à abundância de recurso disponível, já que a energia pode ser produzida mesmo em dias nublados ou chuvosos, além de apresentarem baixo custo relativo de implementação e impacto ambiental reduzido, quando comparados a outros sistemas de geração de energia. Por outro lado, o comportamento dos sistemas fotovoltaicos depende muito do caráter estocástico da provisão luminosa, fator que causa grandes flutuações na geração de energia elétrica e que pode levar o sistema à instabilidade (Lindner et al. (2017)). Nesse cenário, algumas ferramentas tem sido propostas com o objetivo de auxiliar na redução das intempéries associados à geração fotovoltaica, como os modelos de séries temporais (Voyant et al. (2018), Lourenço et al. (2017)), as redes neurais artificiais (Lima (2015) Lourenço et al. (2017), Heinen and Fernandes (2018), Voyant et al. (2018)) e o estudo de fenômenos atmosféricos (Menezes Neto et al. (2009)), propostos para a previsão de dados de radiação e irradiação solar.

Este trabalho tem como objetivo a previsão de irradiação solar em sistemas de geração fotovoltaica utilizando-se a análise de séries temporais. Um parque de painéis fotovoltaicos situado na região de Jequié, Bahia, foi considerado como estudo de caso. Nesta região, o perfil do sinal de irradiação medido é semelhante ao perfil de provisão luminosa, com valores muito baixos durante os períodos sem luminosidade, que se modificam gradativamente a medida que a intensidade da luz solar aumenta, com picos às 12h e o conseqüente decréscimo às 18h. Esse perfil é compartilhado pela maioria dos dias que compõem o conjunto de medidas, realizadas entre os meses de maio de 2013 e junho de 2014, com exceção para os períodos chuvosos ou na ocorrência de sombreamento provocado por nuvens. Com base no aspecto periódico das medidas de irradiação solar, o modelo Periódico Auto-Regressivo (PAR) foi considerado neste trabalho para a previsão de dados horários.

O artigo será organizado da seguinte forma: a seção II apresenta a descrição do problema; a seção III apresenta conceitos da teoria de séries temporais e o modelo periódico auto-regressivo utilizado neste trabalho; a seção IV apresenta os resultados obtidos e a seção V apresenta conclusões sobre o estudo realizado.

2. DESCRIÇÃO DO PROBLEMA

A conversão de energia luminosa em energia elétrica é um processo relativamente barato. Por outro lado, fatores econômicos relacionados à captação deste tipo de recurso, em conjunto com a inconstância da oferta, devido aos efeitos sazonais e climáticos, desfavorecem este tipo de geração. Boas previsões dos valores de irradiação luminosa garantem maior segurança no planejamento da geração fotovoltaica, favorecem os processos de expansão dos sistemas de geração e a redução dos riscos de investimentos econômicos (Menezes Neto et al. (2009) e Lima (2015)).

Do ponto de vista operacional, a modelagem das séries temporais de irradiação pode contribuir para a operação e manutenção de painéis fotovoltaicos. Valendo-se dos resultados da previsão, é possível se avaliar o desempenho

de um painel fotovoltaico, comparando-se as medições de energia gerada pelo equipamento e o valor esperado de geração com base nas previsões, visto que a irradiação solar pode ser relacionada com a potência gerada através de uma função de transferência.

No que segue serão apresentadas algumas características gerais das séries temporais de irradiação solar.

2.1 Caracterização dos dados

Neste trabalho foram considerados dados de medições de irradiação solar realizadas em painéis fotovoltaicos situados na região de Jequié, Bahia, coletados entre os meses de maio de 2013 e junho de 2014. As medições foram realizadas ininterruptamente durante o período, em intervalos de 10 minutos. Os valores horários referem-se à média de cada seis medições realizadas. A fim de caracterizar o comportamento dos dados, as Figuras 1, 2 e 3 apresentam a distribuição das medições ao longo de 24 horas, em diferentes dias do histórico de dados utilizado, respectivamente o 1º, 183º e 365º dias do ano. A Figura 4 apresenta a função de autocorrelação dos dados.




Figura 1. Irradiação solar no 1º dia (W/m^2).




Figura 2. Irradiação solar no 183º dia (W/m^2).

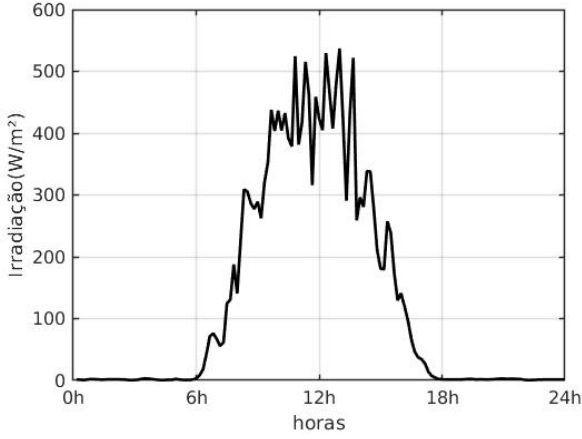


Figura 3. Irradiação solar no 365º dia (W/m^2).




Figura 4. Irradiação solar - autocorrelação parcial.

3. SÉRIES TEMPORAIS

Nessa seção serão apresentados alguns conceitos relacionados à séries temporais, importantes para o desenvolvimento deste trabalho.

3.1 Análise de séries temporais

Uma série temporal consiste em uma variável aleatória indexada no tempo, denotada por $\{x_t, t \in \mathcal{R}_+\}$, sendo \mathcal{R}_+ o conjunto dos números reais não negativos (Papoulis and Pillai (2002)). O que diferencia as séries temporais de outros conjuntos de dados é a dependência entre as observações vizinhas.

As séries temporais são decompostas em 4 componentes: aleatoriedade, ciclicidade, sazonalidade e tendência. A não estacionariedade da série temporal pode ser identificada através da análise da dependência do tempo da distribuição de probabilidades de uma amostra de k observações da série. Se a distribuição de probabilidades não depender do tempo, a série é estacionária. Tal verificação pode ser feita através da observação da dependência do tempo das distribuições unidimensionais pois, caso a série seja estacionária, a média e o desvio padrão são invariantes à translações no tempo (Ballini (2000)). A série temporal de irradiação solar apresenta o caráter não estacionário. Geralmente, as séries temporais não estacionárias podem ser representadas pela combinação das componentes sazonal, s_t , e estacionária, \tilde{z}_t :

$$x_t = s_t + \tilde{z}_t + a_t \quad (1)$$

onde a_t é o ruído branco gaussiano.

A remoção do caráter não estacionário é realizada com a mudança de variável representada pela seguinte equação:

$$z_t = \frac{x_t - \mu_m}{\sigma_m} \quad (2)$$

Na equação (2), μ_m e σ_m são a média e o desvio padrão da série temporal, respectivamente. A série padronizada obtida apresenta, aproximadamente, média zero e variância unitária. Os dados de irradiação apresentam uma componente de sazonalidade, pois, assim como a provisão de luz solar, é possível observar um comportamento periódico nos dados medidos.

3.2 Modelo Periódico Auto-Regressivo (PAR)

A séries temporais que apresentam comportamento periódico podem ser analisados por modelos periódicos auto-regressivos. Seja x_1, x_2, \dots, x_{ns} uma série temporal com período s , número de dias n , índice de tempo definido em função do número de dias $r = 1, 2, \dots, n$ e horas $m = 1, 2, \dots, s$. Assim, $x_{t(r,m)}$ representa a observação da série x_t no dia r e na hora m . Os modelos periódicos auto-regressivos de ordem p_m , $m = 1, 2, \dots, s$, PAR(p_m), podem ser representados da seguinte forma (Ballini (2000), Box et al. (2008)):

$$z_{t(r,m)} = \sum_{i=1}^{p_m} \phi_{i,m} z_{t(r,m)-i} + a_{t(r,m)} \quad (3)$$

Na equação (3), $\phi_{i,m}$ é uma função periódica com período s , $a_{t(r,m)}$ é um ruído branco com distribuição normal $N(0, \tau_m^{-1})$, $\tau_m^{-1} = \sigma_m^2$ e $\tau_m > 0$. Por fim, $z_{t(r,m)}$ é a série padronizada, que possui, aproximadamente, média nula e desvio padrão unitário.

Há diferentes formas de estimar os parâmetros dos modelos PAR(p_m). Neste trabalho, o método da Máxima Verossimilhança foi considerado, em que a obtenção dos parâmetros $\phi_{i,m}$ é feita através da função de verossimilhança condicional:

$$L_m(\Phi_m, \tau_m | \mathbf{Z}_m) \propto \tau_m^{\frac{n_m}{2}} \exp\left\{-\frac{\tau_m}{2} (\mathbf{Z}_m - \mathbf{X}_m \Phi_m)' (\mathbf{Z}_m - \mathbf{X}_m \Phi_m)\right\} \quad (4)$$

Os parâmetros da função de verossimilhança (4) são definidos como:

$$n_m = \begin{cases} n-1, & m = 1, \dots, p_m \\ n, & m = p_m + s \end{cases}$$

$$\mathbf{Z}_m = \begin{pmatrix} z_{t(1,m)} \\ z_{t(2,m)} \\ \vdots \\ z_{t(n,m)} \end{pmatrix}_{n \times 1} \quad \Phi_m = \begin{pmatrix} \phi_{t(1,m)} \\ \phi_{t(2,m)} \\ \vdots \\ \phi_{t(n,m)} \end{pmatrix}_{n \times 1}$$

$$\mathbf{X}_m = \begin{pmatrix} z_{t(1,m)} & \cdots & z_{t(1,m)-p_m} \\ z_{t(2,m)} & \cdots & z_{t(2,m)-p_m} \\ \vdots & \ddots & \vdots \\ z_{t(n,m)} & \cdots & z_{t(n,m)-p_m} \end{pmatrix}$$

O desenvolvimento do método consistem em aplicar a função logaritmo em (4):

$$l_m(\Phi_m, \tau_m | \mathbf{Z}_m) = \frac{n_m}{2} \ln(\tau_m) - \frac{\tau_m}{2} (\mathbf{Z}_m - \mathbf{X}_m \Phi_m)' (\mathbf{Z}_m - \mathbf{X}_m \Phi_m) \quad (5)$$

Em seguida, aplica-se as derivadas parciais em relação a Φ_m e τ_m , igualando-as a zero. Esse processo dá origem aos estimadores de máxima verossimilhança:

$$\hat{\Phi}_m = (\mathbf{X}_m' \mathbf{X}_m)^{-1} (\mathbf{X}_m \Phi_m - \mathbf{Z}_m) \quad (6)$$

$$\hat{\tau}_m^{-1} = (\mathbf{Z}_m - \mathbf{X}_m \hat{\Phi}_m)' (\mathbf{Z}_m - \mathbf{X}_m \hat{\Phi}_m) \quad (7)$$

Na seção seguinte são apresentados os ajustes realizados e resultados obtidos.

4. RESULTADOS

Neste trabalho as previsões dos dados de irradiação solar utilizando o modelo PAR são realizadas em base horária. Duas situações foram consideradas em relação a ordem do modelo PAR: o modelo PAR de ordem 1, onde o parâmetro de previsão depende apenas da hora anterior à previsão, e o modelo PAR(p_m), onde a ordem do modelo varia com a hora da previsão. Em ambos modelos foram considerados ajustes dos parâmetros de previsão referentes a cada hora de um dia.

O ajuste dos parâmetros de previsão do modelo PAR foi realizado utilizando-se os dados históricos de irradiação solar, retirando-se desses dados as séries utilizadas para teste da previsão. Os testes foram realizados considerando-se a previsão de 3 dias consecutivos, sendo selecionados dias do histórico de irradiação que apresentavam características diferentes em relação à luminosidade: dias de irradiação solar medianas e dias de irradiação baixas. Em períodos de pouca irradiação solar a geração fotovoltaica está mais propensa a sofrer falhas e aumentam-se os riscos de instabilidade no sistema, tornando ainda mais relevante se ter uma boa previsão em tais períodos.

Para avaliar a qualidade da previsão, foi considerado o cálculo da raiz do erro médio quadrado (*Root Mean Square Error* (RMSE)), definido como:

$$RMSE = \sqrt{\frac{\sum_{i=1}^{p_m} (X_{obs,i} - X_{prev,i})^2}{n}} \quad (8)$$

onde $X_{obs,i}$ é o valor associado ao dado observado e $X_{prev,i}$, o resultado da previsão.

No que segue são apresentados os resultados obtidos pelo modelo PAR.

4.1 Modelo Periódico Auto-Regressivo de ordem 1 (PAR(1))

O modelo PAR(1) considera que a irradiação solar na hora corrente depende apenas da irradiação solar da hora imediatamente anterior.

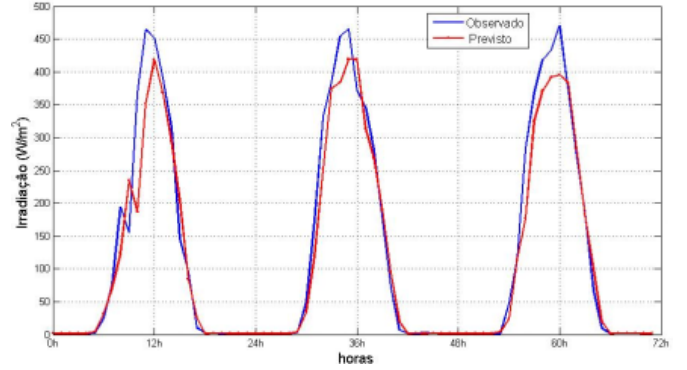
A tabela 1 mostra os parâmetros $\phi_{1,m}$ para o modelo PAR(1) obtidos considerando-se os dados históricos de irradiação solar, retirando-se os 3 últimos dias, período considerado de irradiações medianas. Foram considerados 24 parâmetros, sendo um parâmetro para cada hora do

dia, e um horizonte de previsão de 72 horas. A figura 5 apresenta os dados reais e a previsão no período considerado. Neste caso o erro de previsão obtido foi RMSE = 38,46%

Tabela 1. Parâmetros ϕ_1 para o PAR(1) - irradiação solar mediana

Hora	$\phi_{1,m}$	Hora	$\phi_{1,m}$
1	-0.0093	13	0.8740
2	0.1789	14	0.8787
3	0.0815	15	0.8404
4	0.1828	16	0.8351
5	0.2181	17	0.7727
6	0.0236	18	0.6703
7	0.7080	19	0.7340
8	0.7375	20	0.1396
9	0.8254	21	0.2050
10	0.8087	22	0.2898
11	0.8266	23	0.1539
12	0.8484	24	0.0936

Figura 5. Previsão do modelo PAR(1), horizonte de 3 dias e período de irradiação solar medianas.



Pode-se observar, de acordo com a Figura 5, que o modelo PAR(1) forneceu a previsão que segue o perfil do série observada de forma adequada. As maiores diferenças são verificadas nos horários de pico da série.

A fim de analisar o comportamento do PAR(1) em períodos com diferentes intensidades de irradiação solar, a tabela 2 mostra os parâmetros $\phi_{1,m}$ para o modelo PAR(1) obtidos considerando-se os dados históricos de irradiação solar, retirando-se os 3 últimos dias de menores registros de irradiação solar, período considerado de irradiações baixas. Foram considerados 24 parâmetros, referentes a cada hora do dia, e um horizonte de previsão de 72 horas. A figura 6 apresenta os dados reais e a previsão no período neste caso, onde o erro de previsão obtido foi RMSE = 16,90%

4.2 Modelo Periódico Auto-Regressivo de ordem p_m (PAR(p_m))

O PAR(p_m) considera que a irradiação solar na hora corrente depende de dados de irradiação solar de m horas imediatamente anteriores. Neste caso a ordem do modelo varia para cada uma das 24 horas consideradas.

A tabela 3 mostra os parâmetros $\phi_{p,m}$ para cada hora do dia, obtidos considerando-se os dados históricos de irradiação solar, retirando-se os 3 últimos dias, período considerado de irradiações medianas. Observa-se que o


Tabela 2. Parâmetros ϕ_1 para o PAR(1) - irradiação solar baixa

Hora	$\phi_{1,m}$	Hora	$\phi_{1,m}$
1	0.0068	13	0.8763
2	0.1790	14	0.8805
3	0.0793	15	0.8489
4	0.1806	16	0.8324
5	0.2161	17	0.7816
6	0.0269	18	0.6739
7	0.7116	19	0.7340
8	0.7316	20	0.1441
9	0.8251	21	0.1924
10	0.8054	22	0.2871
11	0.8234	23	0.1650
12	0.8498	24	0.1015

Tabela 3. Parâmetros $\phi_{n,m}$ para o PAR(p_m) - irradiação mediana.


Hora	$\phi_{1,m}$	$\phi_{2,m}$	$\phi_{3,m}$	$\phi_{4,m}$	$\phi_{5,m}$
1	0.0030	-0.1311	0	0	0
2	0.1789	0	0	0	0
3	0.0815	0	0	0	0
4	0.1982	-0.1869	0	0	0
5	0.2161	0	0	0	0
6	0.0269	0	0	0	0
7	0.7116	0	0	0	0
8	0.9410	-0.3183	-0.0727	-0.0876	-0.0822
9	0.8948	-0.0315	-0.1307	0	0
10	0.9402	-0.2927	0.2410	-0.1370	0
11	0.8234	0	0	0	0
12	0.9797	-0.1579	0	0	0
13	1.0386	-0.1906	0	0	0
14	0.9987	-0.1355	0	0	0
15	1.0338	-0.2102	0	0	0
16	0.8324	0	0	0	0
17	0.9244	-0.1714	0	0	0
18	0.8724	-0.2547	0	0	0
19	0.7340	0	0	0	0
20	0.1441	0	0	0	0
21	0.1692	0.1599	0	0	0
22	0.2871	0	0	0	0
23	0.1650	0	0	0	0
24	0.1283	-0.1629	0	0	0

Figura 6. Previsão do modelo PAR(1), horizonte de 3 dias e período de irradiação solar baixas.



modelo PAR(p_m) apresentou ordem um ou dois para a maior parte das horas do dia, com exceção das horas 8 e 10, que apresentam ordem 5 e 4, respectivamente. Foi considerado um horizonte de previsão de 72 horas. A figura 7 apresenta os dados reais e a previsão no período considerado, sendo o erro de previsão RMSE = 36,59%

Figura 7. Previsão do modelo PAR(p_m), horizonte de 3 dias e período de irradiação solar medianas.




De acordo com a Figura 7 as maiores diferenças ocorreram no pico das séries, normalmente por volta do meio dia, de forma semelhante ao modelo PAR(1), (Figura 5). Os erros no período considerado foram bastante próximos no caso do PAR(1) e PAR(p_m), 38,46% e 36,59% respectivamente. Vale observar que no modelo PAR(p_m), das 24 horas do dia, 12 horas apresentaram modelo PAR de ordem superior

a um, sendo que destas 12 horas, apenas 3 horas apresentaram ordem superior a dois, o que pode justificar a similaridade de comportamento entre os modelos PAR(1) e PAR(p_m) no horizonte considerado.

A tabela 4 mostra os parâmetros $\phi_{p,m}$ para a o modelo PAR(p_m) obtidos considerando-se os dados históricos de irradiação solar, retirando-se os 3 últimos dias de menores registros de irradiação solar, período considerado de irradiações baixas. A figura 8 apresenta os dados reais e a previsão no período neste caso, em que o erro de previsão obtido foi RMSE = 18,32%.

Figura 8. Previsão do modelo PAR(p_m), horizonte de 3 dias e período de irradiação solar baixas.



Pode-se observar, de acordo com a Figura 8, que para o caso de baixos valores de irradiação solar, o modelo PAR(p_m) apresentou discrepâncias maiores no primeiro dia de previsão, quando comparado com o resultado do modelo PAR(1) no mesmo período (Figura 6)). Como consequência, o erro de previsão neste caso foi maior do que o obtido com o modelo PAR(1) no período (18,32% no caso do PAR(p_m) e 16,90% no caso do PAR(1)).

Tabela 4. Parâmetros $\phi_{n,m}$ para o PAR(p_m) - irradiação baixa.

Hora	$\phi_{1,m}$	$\phi_{2,m}$	$\phi_{3,m}$	$\phi_{4,m}$	$\phi_{5,m}$
1	0.0211	-0.1361	0	0	0
2	0.1790	0	0	0	0
3	0.0793	0	0	0	0
4	0.1953	-0.1869	0	0	0
5	0.2181	0	0	0	0
6	0.0236	0	0	0	0
7	0.7138	-0.0893	-0.0251	-0.1215	0
8	0.9300	-0.3062	-0.0718	-0.0887	-0.0893
9	0.8899	-0.0239	-0.1331	0	0
10	0.9441	-0.2924	0.2391	-0.1361	0
11	0.8226	0	0	0	0
12	0.9780	-0.1571	0	0	0
13	1.0296	-0.1830	0	0	0
14	0.9855	-0.1257	0	0	0
15	1.0529	-0.2421	0	0	0
16	0.8531	0	0	0	0
17	0.9343	-0.1945	0	0	0
18	0.8479	-0.2300	0	0	0
19	0.7340	0	0	0	0
20	0.1789	0	0	0	0
21	0.1847	0.1457	0	0	0
22	0.2892	0	0	0	0
23	0.1539	0	0	0	0
24	0.1138	-0.1299	0	0	0

De uma forma geral, ficou comprovada a eficiência do modelo PAR na previsão de dados de irradiação solar. A diferença de erro de previsão (RMSE) nos modelos PAR(1) e PAR(p_m) não são significativos, sendo menores que 2%. Assim, usar um modelo de ordem 1 pode ser interessante neste caso, em especial se a ordem do modelo de previsão tiver influência sobre os demais processos onde o resultado da previsão poderá ser utilizado.

5. CONCLUSÃO

A previsão de irradiação solar é uma ferramenta de grande valia para o planejamento da geração fotovoltaica e para os procedimentos e programações acerca de manutenção de painéis fotovoltaicos.

Neste trabalho o modelo periódico auto-regressivo foi proposto para a previsão de irradiação solar. Os modelos periódicos auto-regressivos de ordem 1 e ordem p_m foram considerados, cujos parâmetros foram ajustados de acordo com o Método da Máxima Verossimilhança. Para o ajuste dos parâmetros dos modelos PAR foram utilizados dados histórico horários de irradiação solar de um parque de painéis fotovoltaicos situado na região de Jequié, no estado da Bahia, levando-se em consideração as 24 horas do dia.

Foram realizados testes considerando-se a previsão de 3 dias consecutivos (72 horas), sendo selecionados dias do histórico de irradiação com características diferentes em relação à luminosidade: dias de irradiação solar medianas e dias de irradiação baixas. Os dias selecionados para a previsão de vazão não foram utilizados no ajuste dos parâmetros dos modelos periódicos auto-regressivos de ordem 1 e ordem p_m .

A qualidade de previsão foi avaliada pelo cálculo da raiz do erro médio quadrado e, de uma forma geral, os modelos

PAR considerados apresentaram resultados bastante semelhantes, comprovando a ideia de comportamento periódico da série de irradiação solar. Como a diferença de erro de previsão entre o modelo periódico auto-regressivo de ordem 1 e ordem p_m não é significativa, usar um modelo de ordem 1 pode ser interessante neste caso. Menores erros de previsão foram verificados em períodos de irradiação solar baixa para os dois modelos. Trata-se de uma característica importante do modelo de previsão, já que em períodos com baixa irradiação solar a geração fotovoltaica está mais propensa a sofrer falhas e causar instabilidades, tornando ainda mais relevante se ter uma boa previsão em tais períodos.

AGRADECIMENTOS

Os autores agradecem ao Conselho de Desenvolvimento Científico e Tecnológico CNPq pelo apoio financeiro.

REFERÊNCIAS

- ANEEL (2008). Atlas brasileiro de energia elétrica. *Agência Nacional de Energia Elétrica, Brasília, Brasil. 3aEd.*
- Ballini, R. (2000). *Análise e previsões de vazões utilizando modelos de series temporais, redes neurais e redes neurais nebulosas.* Tese de doutorado, Doutorado em Engenharia Elétrica, Unicamp.
- Bondarik, R., Pilatti, L.A., and Horst, D.J. (2018). Uma visão geral sobre o potencial de geração de energias renováveis no brasil. *Interciencia*, 43(10), 680–688.
- Box, G.E.P., Jenkins, G.M., and Reinsel, G.C. (2008). *Time Series Analysis: Forecasting and Control.* Prentice-Hall International, Inc.
- Heinen, E.D. and Fernandes, R.A.S. (2018). Redes neurais recorrentes aplicadas a previsão de radiação solar no horizonte de curto prazo. *IX Computer on the Beach*, 841–849.
- Lima, F.d. (2015). Previsão de irradiação solar no nordeste do brasil empregando o modelo WRF ajustado por redes neurais artificiais (RNAs). *São José dos Campos: INPE.*
- Lindner, M., Witzmann, R., Marggraf, O., Laudan, S., Engel, B., Patzack, S., Vennergeerts, H., Götde, M., Potratz, F., and Schenettler, A. (2017). Estabilidade de rede com fontes de energia renovável. *Fotovolta*, 3(10), 28–31.
- Lourengo, L.F.N., de Camargo Salles, M.B., Gemignani, M.M.F., Gouvea, M.R., and Kagan, N. (2017). Time series modelling for solar irradiance estimation in northeast brazil. In *2017 IEEE 6th International Conference on Renewable Energy Research and Applications (ICRERA)*, 401–405. IEEE.
- Menezes Neto, O.L., Costa, A., and Ramalho, F. (2009). Estimativa de radiação solar via modelagem atmosférica de mesoescala aplicada à região nordeste do brasil. *Revista Brasileira de Meteorologia*, 24(3), 339–345.
- Papoulis, A. and Pillai, S.U. (2002). *Probability, random variables, and stochastic processes.* Tata McGraw-Hill Education.
- Voyant, C., De Gooijer, J.G., and Notton, G. (2018). Periodic autoregressive forecasting of global solar irradiation without knowledge-based model implementation. *Solar Energy*, 174, 121–129.