

**Influência do el niño e da la niña na previsão intra-horária da irradiação solar global horizontal****Influence of el niño and la niña on the intrahorary forecast of horizontal global solar irradiation**

DOI:10.34117/bjdv6n1-169

Recebimento dos originais: 30/11/2019

Aceitação para publicação: 15/01/2020

**Juliana Silva Brasil**

Mestranda em Engenharia Mecânica pela Universidade Federal do Ceará

Instituição: Universidade Federal do Ceará

Endereço: Campus do Pici, Av. Humberto Monte, s/n - Pici, Fortaleza – CE, Brasil

E-mail: julianasbra@gmail.com

**Felipe Pinto Marinho**

Mestrando em Engenharia Mecânica pela Universidade Federal do Ceará

Instituição: Universidade Federal do Ceará

Endereço: Campus do Pici, Av. Humberto Monte, s/n - Pici, Fortaleza – CE, Brasil

E-mail: felipe.pinto.marinho@gmail.com

**Paulo Alexandre Costa Rocha**

Doutorado em Engenharia Civil pela Universidade Federal do Ceará

Instituição: Universidade Federal do Ceará

Endereço: Campus do Pici, Av. Humberto Monte, s/n - Pici, Fortaleza – CE, Brasil

E-mail: paulo.rocha@ufc.br

**RESUMO**

O presente trabalho consiste em avaliar a influência do el niño e da la niña na previsão da irradiação global horizontal da cidade de Fortaleza, Ceará, nos horizontes temporais de 2 min, 10 min e 30 min. essa influência foi inserida através do The Oceanic Niño Index, ONI. O banco de dados utilizados fazia referência aos anos de 2007 a 2019, com exceção dos anos 2009 e 2011. Foram utilizados modelos de aprendizagem de máquinas, florestas aleatórias - RF e rede neural artificial perceptron de múltiplas camadas - ANN, e um método de persistência, que serve de padrão mínimo de desempenho para avaliação dos métodos. A comparação de desempenho dos modelos foi feita, principalmente, pelo valor do nRMSE, que é a raiz do erro quadrático médio. Para a previsão foram considerados como preditores: temperatura e umidade do ar, velocidade e direção do vento, precipitação, irradiação do

instante atual e de 5 instantes anteriores, data e hora da coleta do dado e o ONI. Os resultados apontam que as previsões realizadas com o preditor ONI apresentaram menor erro do que as sem essa variável, o que ressalta a importância desse preditor. Além disso, tanto os resultados do RF quanto do ANN apresentaram erros inferiores ao modelo de persistência, sendo o RF o método de melhor desempenho.

**Palavras-chave:** Previsão, Aprendizagem de máquina, Irradiação solar global, El Niño e La Niña.

## ABSTRACT

The present work is to evaluate the influence of el niño and la niña on the prediction of the horizontal global irradiation of the city of Fortaleza, Ceará, in the time horizons of 2 min, 10 min and 30 min. This influence was inserted through The Oceanic Niño Index, ONI. The database used referred to from 2007 to 2019, except for 2009 and 2011. Machine learning models, random forests - RF and multilayer perceptron artificial neural network - ANN, and a persistence method were used. , which serves as the minimum performance standard for method evaluation. The performance comparison of the models was made mainly by the value of nRMSE, which is the root of the mean square error. For the forecast were considered as predictors: air temperature and humidity, wind speed and direction, precipitation, irradiation of the current instant and 5 previous instants, date and time of data collection and ONI. The results indicate that the predictions made with the ONI predictor presented lower error than those without this variable, which highlights the importance of this predictor. In addition, both the RF and ANN results showed errors lower than the persistence model, with RF being the best performing method.

**Keywords:** Forecasting, Machine learning, Global solar irradiation, El Niño and La Niña.

## 1 INTRODUÇÃO

A crescente representatividade da energia solar na matriz energética brasileira traz consigo questões relativas à complementaridade de abastecimento, uma vez que a fonte solar é intermitente [1]. Seja para uso doméstico quanto em parques solares, que fornece energia para a rede elétrica, é útil saber quando ocorrerão reduções na disponibilidade do recurso solar. Essa informação evita quedas no fornecimento de eletricidade, bem como o consumo desnecessário de outras fontes [2].

O estado do Ceará se destaca na geração de energia por fontes renováveis, dentre as quais a solar, uma vez que a região é favorecida pelas altas taxas de incidência solar [3]. A geração solar na região representa uma alternativa à produção hidrelétrica local, que é bastante afetada pelos períodos de escassez de chuvas, e que geralmente acarretam aumento na tarifa de energia.

Previsões confiáveis de irradiação são uma alternativa para identificar prováveis períodos de redução na disponibilidade do recurso solar. Estas previsões podem ser feitas em diferentes horizontes temporais, de minutos a dias, estas necessárias para o agendamento de manutenções preventivas e àquelas necessárias para previsão de quedas de fornecimento [1].

O El Niño e a La Niña são fenômenos climáticos de aquecimento e resfriamento, respectivamente, da camada mais superficial do oceano Pacífico equatorial [4]. Esses eventos alteram os regimes de chuvas e ventos, provocando impactos globais no clima [5].

Assim, este trabalho tem por objetivo avaliar a influência da intensidade dos fenômenos climáticos El Niño e La Niña, *The Oceanic Niño Index* (ONI), como preditor para a realização de previsões de irradiação solar global horizontal em horizontes de tempo de 2 min, 10 min e 30 min, utilizando os algoritmos de aprendizagem supervisionada Florestas Aleatórias (RF) e Rede Neural Artificial Percéptron de Múltiplas Camadas (ANN), além de um modelo de persistência (P), que funciona como uma cota inferior para avaliação do desempenho de outros modelos de previsão.

Os resultados apontaram que a adição do preditor ONI reduziu a raiz do erro quadrático médio (RMSE) relacionado à previsão, bem como verificou-se que tanto o RF quanto o ANN apresentaram um menor valor de RMSE quando comparados com o modelo de persistência, sendo o RF o modelo de melhor desempenho.

## 2 METODOLOGIA

Os dados foram coletados na cidade de Fortaleza, Ceará, 3° 43' 2''S, 38° 32' 35'' O, durante os anos de janeiro de 2007 a dezembro de 2013 (com exceção do anos de 2009 e 2011). Destes, os dados meteorológicos foram obtidos por meio da Fundação Cearense de Meteorologia e Recursos Hídricos - Funceme [6], enquanto os dados de irradiação solar foram coletados pelo Laboratório de Energia Solar e Gás Natural - LESGN, da Universidade Federal do Ceará.

Foram considerados neste trabalho os preditores: ano, dia e horário da aquisição das observações, temperatura e umidade relativa do ar, velocidade e direção do vento, precipitação, irradiação do instante atual e irradiação de 5 instantes anteriores (2 min, 4 min, 6 min, 8 min, 10 min).

Por meio dos valores de irradiação solar calculou-se o índice de claridade (Kt) que é a razão entre a irradiação solar medida e a irradiação solar máxima que atinge a terra em um dado instante [7]. O dia do ano foi normalizado a fim de reduzir sua amplitude de valores [8].

Também foi acrescentado como preditor o *The Oceanic Niño Index* (ONI), que avalia a intensidade do El Niño e da La Niña, variando de -4 (La Niña forte) a 4 (El Niño forte). Essa informação foi obtida pelo *National Oceanic and Atmospheric Administration* (NOOA) órgão do governo estadunidense [9].

### 3 MODELOS

**Florestas Aleatórias** - Trata-se de um método de árvores de regressão, que consiste em gerar várias árvores de decisão que têm posteriormente seus resultados combinados. Por agregar muitos modelos é considerado um método *Ensemble*. Este método faz uma árvore de regressão com um procedimento de *Bootstrap Aggregation* (BAGGING), mas com a característica de selecionar aleatoriamente  $m$  preditores do número total de atributos a fim de reduzir a variância do modelo [10].

Para determinar o número de árvores ótimo para a realização das previsões foi utilizado o procedimento de reamostragem validação cruzada [11].

**ANN (Redes Neurais Artificiais)** - é um tipo de rede neural classicamente aplicada em problemas de previsão [12]. A arquitetura da rede utilizada neste trabalho consiste de 3 camadas, entrada, intermediária, ou oculta, e saída. O método recebe esse nome por se assemelhar às transmissões entre neurônios no corpo humano. Caracteriza-se pela presença de neurônios, ou nós, que ao receberem as informações de neurônios anteriores, lhes atribuem pesos distintos e posteriormente as somam. Esse somatório passa por uma função de ativação, que fornece a resposta estimada [13].

A obtenção do número de neurônios da camada intermediária que fornece o menor erro para a previsão foi feita por meio da realização de sucessivas abordagens de subconjunto de validação.

**Persistência** - Consiste de um modelo para servir de parâmetro de erro para os demais métodos. Nele considerou-se que o índice de claridade do instante posterior seria igual ao índice de claridade do instante anterior, conforme Equação 1.

$$Kt_t = Kt_{t-\Delta t} \quad (1)$$

**4 MÉTRICAS DE ERRO**

São necessárias para comparar os métodos e avaliar a adequação destes ao banco de dados trabalhado.

- **Raiz do Erro Quadrático Médio (RMSE)** - O RMSE é um importante parâmetro de avaliação do ajuste de um modelo, é calculado pela raiz do erro médio ao quadrado, onde o erro médio é a média da diferença entre o valor predito,  $\hat{K}t$ , e o valor real,  $Kt$ , Conforme a Equação 2. É dado na mesma unidade da variável predita. E  $N$  é o número de observações.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\hat{K}t - Kt)^2}{N}} \quad (2)$$

- **Raiz do Erro Quadrático Médio Relativo (nRMSE)** - É a razão entre o RMSE e a média dos valores reais da variável,  $\overline{Kt}$ , conforme Equação 3. É obtido na forma de porcentagem. Essa métrica de erro fornece uma faixa de classificação para a previsão, a saber:  $nRMSE < 10\%$  excelente,  $10\% < nRMSE < 20\%$  bom,  $20\% < nRMSE < 30\%$  razoável e  $nRMSE \geq 30\%$  ruim [14].

$$nRMSE = \frac{RMSE}{\overline{Kt}} \quad (3)$$

- **Erro Absoluto Médio (MAE)** - É a média do valor absoluto da diferença entre o valor predito e o valor real, conforme Equação 4. Nesta métrica os erros individuais são ponderados igualmente pela média, diferentemente do RMSE.

$$MAE = \frac{\sum_{i=1}^N |\hat{K}t - Kt|}{N} \quad (4)$$

- **Erro Absoluto Médio Normalizado (nMAE)** - É a razão entre o MAE e a média dos valores reais da variável, conforme Equação 5.

$$nMAE = \frac{MAE}{\overline{Kt}} \quad (5)$$

**5 RESULTADOS E DISCUSSÃO**

Para ambas as previsões, com e sem o preditor ONI, e para todos os modelos, verificou-se que os valores de nRMSE aumentaram quanto mais distantes estavam os horizontes temporais, conforme sugerido em [15].

Considerando o preditor ONI, o método que apresentou menor nRMSE para os três tempos considerados foi o RF (25,24% - 2min, 31,39% - 10min, 33,08% - 30min), seguido do ANN (26,22% - 2min, 33,44% - 10min, 45,38% - 30min) e do modelo de persistência (29,28% - 2min, 40,28% - 10min, 50,77% - 30min), conforme indicado nas Tabelas 1 e 2. Desconsiderando o preditor ONI, verificou-se comportamento similar em relação aos métodos de melhor desempenho, entretanto os valores de nRMSE foram, no geral, ligeiramente maiores, o que indica que a adição do preditor ONI influencia positivamente no desempenho dos métodos.

Tabela 1. Resultados considerando o preditor ONI.

c/ ONI	2min			10min			30min		
	RF	ANN	P	RF	ANN	P	RF	ANN	P
RMSE	0,1305	0,1356	0,1514	0,1616	0,1721	0,2074	0,1712	0,2349	0,2628
nRMSE	25,24	26,22%	29,28%	31,39%	33,44%	40,28%	33,08%	45,38%	50,77%
MAE	0,0776	0,0814	-	0,1056	0,1172	-	0,1177	0,1659	-
nMAE	0,1501	0,1574	-	0,2052	0,2277	-	0,2274	0,3206	-
S	13,80%	10,43%	-	22,08%	17,02%	-	34,85%	10,61%	-

Tabela 2. Resultados desconsiderando o preditor ONI.

s/ ONI	2min			10min			30min		
	RF - 5	ANN	P	RF - 6	ANN	P	RF - 8	ANN	P
RMSE	0,1305	0,1363	0,1514	0,1617	0,1747	0,2074	0,1713	0,2010	0,2628
nRMSE	25,23	26,36%	29,28%	31,42%	33,93%	40,28%	33,11%	38,83%	50,77%
MAE	0,0775	0,0822	-	0,1057	0,1186	-	0,1178	0,1463	-
nMAE	0,1499	0,1589	-	0,2055	0,2305	-	0,2277	0,2827	-
S	13,80%	9,97%	-	22,03%	15,76%	-	34,81%	23,51%	-

Quanto ao MAE e ao nMAE o comportamento foi similar ao do RMSE, com o RF apresentando melhor desempenho (0,0776 - 2 min, 0,1501 – 2min, respectivamente) para o horizonte de 2 min, considerando o preditor ONI.

As previsões para 2 min foram as únicas que apresentaram valores de nRMSE dentro da faixa ‘razoável’. As previsões de 10min e 30min apresentaram resultados classificados dentro da faixa ‘ruim’ [14].

## **6 CONSIDERAÇÕES FINAIS**

Realizaram-se previsões de irradiação solar global usando os métodos, RF, ANN e de persistência. A adição da intensidade do El Niño e La Niña, ONI, como preditor melhorou a performance dos modelos, sendo o algoritmo de florestas aleatórias o método que melhor se adequou aos dados em estudo. Verificou-se que quanto mais distante o horizonte temporal maior o erro para todos os métodos, com e sem o preditor ONI.

Aprimorar a validação cruzada k-fold para o algoritmo de florestas aleatórias e a escolha dos parâmetros da rede neural (número de neurônios e de camadas) são alternativas para melhorar os resultados, bem como verificar quais funções de ativação da ANN são mais adequadas ao banco de dados.

## **AGRADECIMENTOS**

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

## **REFERÊNCIAS**

Notton G, Nivet ML, Voyant C, Paoli C, Darras C, Motte F, Fouilloy A. Intermittent and stochastic character of renewable energy sources: consequences, cost of intermittence and benefit of forecasting. *Renewable and Sustainable Energy Reviews* 2018; 87:96-105.doi:10.1016/j.rser.2018.02.007.

Quing X, Niu Y. Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM. *Energy* 2018; 148:461-468. doi:10.1016/j.energy.2018.01.177.

Menezes OL, Oliveira JL, Vasconcelos FC, Pereira JMR, Sakamoto MS. Atlas solarimétrico do Ceará 1963-2010. Fundação Cearense de Meteorologia e Recursos Hídricos-Funceme 2011.

Kayano MT, Andreoli RV, Souza RAF, Garcia SR, Calheiros AJP. El niño e la niña nos últimos 30 anos: diferentes tipos. Instituto Nacional de Pesquisas Espaciais, INPE.

Mohammadi K, Goudarzi N. Study of inter-correlations of solar radiation, wind speed and precipitation under the influence of el niño southern oscillation (ENSO) in California. *Renewable Energy* 2018; 120:190-200.doi:10.1016/j.renene.2017.12.069.

Plataforma de Coleta de Dados - PCD - Funceme. <http://funceme.br/pcd/> (accessed September 20, 2019).

Duffie JA, Beckman WA. *Solar Engineering of Thermal Processes*. John Wiley & Son, 2006.  
Zhu T, Xie L, Wei H, Wang H, Zhao X, Zhang K. Clear-sky direct normal irradiance estimation based on adjustable inputs and error correction. *Journal of Renewable and Sustainable Energy* 2019; 11.doi:10.1063/1.5094808.

Historical El niño / La niña episodes (1950 - present). [https://origin.cpc.ncep.noaa.gov/products/analysis\\_monitoring/ensostuff/ONI\\_v5.php](https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php) (accessed May 12, 2019).

Benali L, Notton G, Fouilloy A, Voyant C, Dizene R. Solar radiation forecasting using artificial neural network and random forest methods: applications to normal beam, horizontal diffuse and global components. *Renewable Energy* 2019; 132:871-884.doi:10.1016/j.renene.2018.08.044.

Rohani A, Taki M, Abdollahpour M. A novel soft computing model (Gaussian process regression with K-fold cross validation) for daily and monthly solar radiation forecasting (Part: I). *Renewable Energy* 2018;115:411-422.doi:10.1016/j.renene.2017.08.061.

Rocha PAC, Fernandes JL, Modolo AB, Pontes RJ, Vieira ME, Bezerra CA. Estimation of daily, weekly and monthly global solar radiation using ANNs and a long data set: a case study of Fortaleza, in Brazilian Northeast region. *International Journal of Energy and Environmental Engineering* 2019.doi:10.1007/s40095-019-0313-0.

Inman RH, Pedro HTC, Coimbra CFM. Solar forecasting methods for renewable energy integration. *Progress in Energy and Combustion Science* 2013;39:535-576.doi:10.1016/j.pecs.2013.06.002.



Li MF et al. General models for estimating daily global solar radiation for different solar radiation zones in mainland China. *Energy Conversion and Management* 2013; 70:139-148. doi:10.1016/j.enconman.2013.03.004.

Pedro HTC, Coimbra CFM. Nearest-neighbor methodology for prediction of intra-hour global horizontal and direct normal irradiances. *Renewable Energy* 2015; 80:770-782. doi:10.1016/j.renene.2015.02.061.