

AVALIAÇÃO DE TÉCNICAS PARA A PREDIÇÃO DE CURTO PRAZO DE PRODUÇÃO DE ENERGIA SOLAR

CARLOS ALBERTO SEVERIANO JUNIOR*, FREDERICO GADELHA GUIMARÃES†

**Instituto Federal de Minas Gerais - Campus Sabará*
Av. Serra da Piedade 299,
34515-640 Sabará, MG, Brazil

†*Department of Electrical Engineering*
Universidade Federal de Minas Gerais
Av. Antônio Carlos 6627,
31270-901 Belo Horizonte, MG, Brazil

Emails: carlos.junior@ifmg.edu.br, fredericoguimaraes@ufmg.br

Resumo— Este trabalho avalia a utilização de diversas técnicas para resolver o problema de predição de curto prazo de energia solar a ser produzida em uma estação fotovoltaica. Dentre os métodos escolhidos para o trabalho estão o modelo de Persistência, o modelo Autorregressivo Integrado de Médias Móveis (ARIMA), o método de k vizinhos mais próximos (kNN) e modelo de Máquinas de Aprendizado Extremo (ELM). A base de dados utilizada no trabalho foi um conjunto de medições intervaladas em 30 minutos de irradiação solar, registradas em uma estação fotovoltaica. Os métodos foram comparados em termos de rapidez e acurácia.

Palavras-chave— Energia Solar, Séries Temporais, Predição, kNN, ARIMA, Máquinas de Aprendizado Extremo

Abstract— This work evaluates the application of several techniques to solve very short-term solar forecasting problems. The methods chosen are: Persistence, Autoregressive Integrated Moving Average (ARIMA), k -Nearest Neighbors (kNN) and Extreme Learning Machines (ELM). The database used in the study was a set of discontinuous measurements in 30 minutes solar irradiation observed in a photovoltaic station. The methods were compared in terms of speed and accuracy.

Keywords— Solar Energy, Time Series, Forecasting, kNN, ARIMA, Extreme Learning Machines

1 Introdução

Nas últimas duas décadas, energias renováveis como fotovoltaica, eólica, dentre outras, têm se posicionado como relevantes fontes de geração de eletricidade em redes de energia no mundo todo. Especificamente a energia fotovoltaica, cuja capacidade instalada mundial era de meros 1 GWp no ano 2000, atingiu ao fim de 2014 um patamar de 178 GWp (IEA, 2014). Em alguns países da Europa, a produção de energia solar já integra percentuais significativos durante dias de intensa exposição solar, mais comuns no verão. Por exemplo, a Itália com cerca de 8% de sua demanda sendo provida por fotovoltaicas, a Alemanha com um valor superior a 6% e a Grécia, próxima de 6% (IEA, 2014). Tal cenário incentiva a incorporação de energia solar a redes energéticas que operam com outras fontes de energia, como as fósseis.

Um dos maiores desafios desta incorporação e operação de sistemas de energia solar é lidar com o aspecto variável dessa fonte de energia, cuja disponibilidade está sujeita a condições climáticas como movimento de nuvens e pressão atmosférica, dentre outros. Além disso, é necessário considerar que sua produção é suspensa durante o período noturno. Tudo isso evidencia a importância da utilização de um método de predição que possa descrever com boa precisão a variabilidade associada a esse sistema (Nobre, 2015). Para trabalhos desta

natureza, o termo *predição de muito curto prazo* se aplica a predições de horizontes na escala de minutos a horas, enquanto o termo *predição de curto prazo* já se refere a horizontes um pouco maiores, na escala de horas a dias. Como abordado por (Taylor, 2008) e (Charytoniuk and Chen, 2000), a predição de muito curto prazo tem importância no auxílio a operações de gerenciamento de plantas energéticas cujo contexto possa demandar maior rapidez na resposta, como escalonamento e comercialização. Este trabalho é focado na predição de energia solar de *muito curto prazo*, mais especificamente horizontes de 30 minutos, por se tratar de uma faixa de intervalo muito representativa dessa modalidade de predição. Os dados utilizados foram registrados em um sistema de energia solar localizado em uma região tropical, especificamente em Cingapura.

Para predições de muito curto prazo há ainda um aspecto adicional, que é a necessidade de um retorno rápido por parte do modelo, de modo que haja um tempo hábil para a tomada de decisão dentro de um intervalo de tempo tão reduzido. Portanto, junto de uma boa acurácia, os modelos de predição de curto prazo requerem um bom desempenho em termos de velocidade de retorno.

Em geral, modelos de predição de carga de energia possuem necessidades similares de técnicas com boa capacidade de lidar com relações comple-

xas entre entrada e saída, o que incentiva a adoção de modelos de Inteligência Artificial (Raza and Khosravi, 2015). No caso específico de energia solar, os trabalhos de Mellit and Pavan (2010) e Pedro and Coimbra (2012) utilizam para a solução do problema Redes Neurais Artificiais.

Este trabalho propõe resolução do problema de predição de energia solar a curto prazo a partir da utilização de diversas técnicas. O aspecto variável das curvas de irradiação solar ao longo do ano incentiva uma avaliação ampla de diferentes abordagens para o problema, no sentido de se identificar qual o caminho mais promissor a ser seguido.

O artigo é organizado da seguinte maneira: Seção 2 descreve os dados usados para a predição; Seção 3 discute a etapa de pré-processamento dos dados; Seção 4 descreve os métodos avaliados no estudo; Seção 5 demonstra os experimentos realizados; Seção 6 conclui o artigo com discussões sobre os resultados e propostas de trabalhos futuros.

2 Fonte de Dados

Os dados usados neste trabalho foram obtidos em uma estação de energia solar localizada em Cingapura. A estação é componente de uma rede instalada ao longo da ilha pelo **SERIS** - *Solar Energy Research Institute of Singapore* (Instituto de Pesquisas em Energia Solar de Cingapura) - como parte de um projeto de pesquisa da entidade. Com o objetivo de obter leituras com uma boa resolução espacial, 25 estações do projeto foram distribuídas pela região usando uma malha de 5x5 km como referência. A Figura 1 exibe essa distribuição.




Figura 1: Mapa de Estações do SERIS em Cingapura.

A observação foi feita a partir de registros de irradiação solar, minuto a minuto, com uma taxa de amostragem de 1 Hz. Desse modo, os valores de 30 minutos usados no trabalho correspondem a médias calculadas a partir dos registros minuto a minuto. As especificações da aparelhagem utilizada no trabalho, bem como a análise das me-

dições avaliadas, indicam um erro na ordem de $\pm 0.2\%$.

Dado que o foco deste trabalho é somente nos aspectos de predição do modelo, apenas uma estação central foi escolhida para a análise. Ela está indicada na Figura 1 pelo número **402**.

3 Pré-processamento

Como discutido anteriormente, os valores observados para irradiação solar podem ser interpretados como séries temporais com componentes de tendência e sazonalidade. E nesse caso, melhores resultados de predição passam pela mitigação ou eliminação desses componentes (Zhang and Qi, 2005).

Neste trabalho, o processo de extração de tendências foi realizado a partir detecção de sua versão suavizada, calculada com a aplicação de um filtro de médias móveis. Isso significa que, dada uma série y , seus valores suavizados são representados por $\tilde{y}$, calculados conforme descrito a seguir em 1.

$$\begin{aligned}\tilde{I}_1 &= I_1 \\ \tilde{I}_2 &= (I_1 + I_2 + I_3)/3 \\ \tilde{I}_3 &= (I_1 + I_2 + I_3 + I_4 + I_5)/5 \\ \tilde{I}_4 &= (I_2 + I_3 + I_4 + I_5 + I_6)/5 \\ &\vdots \\ \tilde{I}(t) &= (I_{t-2} + I_{t-1} + I_t + I_{t+1} + I_{t+2})/5\end{aligned}\quad (1)$$




Figura 2: Observações de irradiação solar de 10 de Abril de 2013 a 05 de Abril de 2013 e seus valores suavizados.

A Figura 2 demonstra um exemplo de valores suavizados para um período de observações. A suavização foi feita a partir de um filtro de médias móveis com um intervalo de 5 observações.

No caso dos dados utilizados para este trabalho, o processo de extração de tendência consiste

exatamente na remoção da componente I_t , representada pelos dados suavizados, de dentro das observações de irradiação solar, representadas por I . Desse modo, os valores restantes, que contêm os dados sem a tendência, I_{dt} , passam a constituir a série temporal utilizada no estudo. Esta componente I_{dt} também pode ser interpretada como a parte estocástica da série temporal. Um processo de extração da componente estocástica para análise da série temporal baseado na suavização dos dados é também observado no trabalho de (Pedro and Coimbra, 2012). No entanto, é adotado um método diferente para a suavização dos dados.

$$I = I_{dt} + I_t \quad (2)$$

Em resultados preliminares deste trabalho, foi observado que melhores valores foram obtidos quando o processo de extração de tendências descrito acima foi realizado. Portanto, todos os métodos de predição avaliados neste trabalho utilizaram como dados a série temporal descrita por I_{dt} .

Outro aspecto citado no início desta seção se refere à sazonalidade. No entanto, seu tratamento neste contexto se constitui em uma tarefa mais complexa, visto que condições climáticas são afetadas por diferentes fatores ao longo do ano. Portanto, neste trabalho o ajuste de sazonalidade não é realizado durante esta etapa de pré-processamento, mas deixado a cargo de cada método de predição, caso este o realize.

4 Métodos

Nesta seção são descritos os métodos de predição utilizados neste trabalho.

4.1 Persistência

O modelo de Céu Limpo representa os valores para irradiação solar em que as demais variáveis climáticas são ignoradas. Com esse modelo, a predição de irradiação solar poderia ser calculada com boa precisão através de um modelo determinístico. Porém, nas situações reais as condições climáticas são também influenciadas por uma componente estocástica que afeta fortemente o resultado final de uma predição.

O modelo de Persistência é um método de predição bem comum, que geralmente é utilizado como uma referência na comparação com outros métodos propostos. Ele assume que a predição é realizada em cima de condições climáticas iguais às observadas no tempo corrente. Ou seja, o horizonte de predição seria calculado a partir do valor atualmente observado. Para tanto ele combina o valor corrente observado com valores extraídos do modelo de Céu Limpo, conforme descrito na equação abaixo:

$$\hat{I}_{t+1} = \begin{cases} I_{cs,t+1} & \text{se } I_{cs,t} = 0 \\ \frac{I_{cs,t+1}}{I_{cs,t}} \times I_t & \text{senão} \end{cases} \quad (3)$$

Onde $I_{cs,t}$ representa o valor de irradiação solar para céu limpo no tempo t . Ainda que seja considerado um método mais simples, o modelo de Persistência pode apresentar bons resultados em algumas ocasiões. Por exemplo, em regiões onde os padrões climáticos mudam muito pouco ou de maneira mais lenta. Portanto, sob algumas condições bem específicas, este método pode apresentar desempenhos próximos aos de outros métodos mais avançados.

4.2 ARIMA

O método ARIMA - *Autoregressive Integrated Moving Average*, ou modelo *Autorregressivo Integrado de Médias Móveis* é um dos mais populares modelos de predição de séries temporais (Box et al., 2008). Ele combina um componente autorregressivo com um componente de médias móveis. Sua representação usual, $ARIMA(p, d, q)$, se refere, respectivamente, aos graus de autorregressão, integração e médias móveis, ou seja, p indica a ordem autorregressiva, d é o grau de diferenciação e q representa a ordem do componente de médias móveis.

Um modelo ARIMA para uma série temporal representada por I_t pode ser escrito da seguinte maneira:

$$\tilde{I}_t = (1 - L)^d I_t \quad (4)$$

$$\phi(L)\tilde{I}_t = \theta(L)\varepsilon_t \quad (5)$$

onde $\tilde{I}_t$ é o resultado da predição t , I_t são os valores da série temporal, ϕ_i é uma componente autorregressiva, θ_j é uma componente de médias móveis, L é a componente de defasagem, ε é um erro irreduzível associado.

$$\phi(L) = \left(1 - \sum_{i=1}^p \phi_i L^i \right) \quad (6)$$

$$\theta(L) = \left(1 - \sum_{j=1}^q \theta_j L^j \right) \quad (7)$$

Os parâmetros ϕ_i e θ_j estão associados com as componentes autorregressiva e de médias móveis, respectivamente, enquanto ε_t representa o erro irreduzível associado. L^i representa a componente de defasagem, onde dado x_t , temos $L^k x_t = x_{t-k}$.

A avaliação da correlação entre os valores da série temporal podem auxiliar na elaboração de um modelo ARIMA mais adequado em termos de seus parâmetros. O gráfico de autocorrelação para a componente estocástica de observações em intervalos de 30 minutos é exibido na Figura 3. No




Figura 3: Gráfico de autocorrelação para a componente estocástica.




Figura 4: Gráfico de correlação parcial para a componente estocástica.

gráfico é possível observar valores positivos para um alto número períodos (*lags*), o que sugere um modelo ARIMA com algum grau de diferenciação. O gráfico de autocorrelação parcial, descrito na Figura 4, apresenta um corte logo nos primeiros *lags*, o que indica a utilização de componentes de autorregressão e médias móveis em graus menores.

Como os dados avaliados neste trabalho se constituem em medições separadas por intervalos de 30 minutos, cada entrada do modelo utilizou 48 medições, representando um componente sazonal completa. Para os demais parâmetros citados anteriormente, os valores escolhidos foram $p = 1$, $d = 1$ e $q = 1$.

4.3 *k*-Nearest-Neighbors

O modelo kNN - *k*-Nearest-Neighbors, ou *k*-vizinhos mais próximos, é uma técnica amplamente usada em reconhecimento de padrões e classificação. Basicamente, ele consiste na medição das distâncias entre o elemento em avaliação e os demais elementos do espaço amostral, de modo que os *k* elementos considerados de menor distân-

cia (os *k*-vizinhos mais próximos) são utilizados para definir qual a classe ou valor do elemento em avaliação. No caso do problema em questão, o objetivo é definir um valor de predição com base na observação das séries temporais presentes na base de treinamento. Isso ocorre a partir da comparação entre a série temporal utilizada para a predição e as demais presentes na base de treinamento. Por exemplo, dada uma série temporal extraída da base de treinamento representada por $\langle P_t, O_t \rangle$, onde:

$$P_t = (I_{st,t}, I_{st,t-1}, I_{st,t-2}, \dots, I_{st,t-n}) \quad (8)$$

$$O_t = I_{st,t+1}$$

E dada uma série de entrada usada para teste Q_t , de mesmo tamanho de P_t , esta é comparada com todas as séries temporais presentes na base de treinamento. Essa comparação consiste no cálculo da distância, que é feito a partir da seguinte equação:

$$Dist(s) = \sqrt{\sum_{i=1}^n (P_{s,i} - Q_{t,i})^2} \quad (9)$$

Onde s é uma série temporal pertencente à base de treinamento. Calculadas as distâncias, as *k* séries temporais da base de treinamento com os menores valores são usadas no resultados da predição. Esse valor é calculado pela média dos valores O_t dos *k* vizinhos mais próximos.

O valor mais adequado para *k* foi obtido de maneira empírica. Diversas faixas de valores foram avaliadas em termos de acurácia sendo escolhido para este trabalho $k = 12$.

4.4 Máquinas de Aprendizado Extremo

Máquinas de Aprendizado Extremo (*Extreme Learning Machines* - ELM) (Huang et al., 2006) possuem uma arquitetura similar a uma rede neural artificial de camada única. Elas diferem, no entanto, quanto ao processo de aprendizado. Seu algoritmo é baseado na teoria de minimização do risco empírico e requer somente uma iteração. Considerando n amostras no formato $(x_i, y_i) \in X \times Y$, $i = 1, \dots, N$, onde:

$x_i = [x_{i1}, x_{i2}, \dots, x_{in}]$ com $X \subset \mathbb{R}^n$ e $y_i = [y_{i1}, y_{i2}, \dots, y_{im}]$ com $Y \subset \mathbb{R}^m$. O processo de treinamento consiste basicamente em duas etapas:

1. Encontrar um mapeamento intermediário

$$H = f(XZ) \quad (10)$$

O mapeamento intermediário H é um resultado de uma função de ativação f aplicada a uma projeção feita com a entrada X e um conjunto de pesos Z , onde um peso z_{ij} conecta um nodo de entrada i a um nodo j pertencente à camada escondida. Os valores de

Z são escolhidos aleatoriamente. O objetivo é converter a entrada original em um problema solucionável linearmente.

2. Encontrar uma solução para o problema linear

$$\hat{Y} = HW \quad (11)$$

onde $\hat{Y}$ é a solução e W é uma matriz de pesos que conecta a camada escondida com a camada de saída. Para resolver este problema, os valores de W são obtidos a partir da base de treinamento Y e a pseudoinversa de Moore-Penrose do mapeamento $H^\dagger$, como descrito abaixo:

$$W = YH^\dagger \quad (12)$$

Obtida a matriz W , o modelo é treinado e pode ser aplicado a amostras de teste seguindo passos similares. Dado um conjunto de dados de entrada X_{test} :

$$H_{test} = h(X_{test}Z) \quad (13)$$

$$Y_{test} = H_{test}W \quad (14)$$

Neste trabalho, o modelo usa como entrada um trecho da série temporal de irradiação solar referente a observações passada. Por exemplo, dado um instante corrente t e um conjunto de n observações anteriores, o modelo usa como dados de entrada as observações registradas nos instantes de $t - n$ a t com o objetivo de prever o valor y a ser observado no instante $t + 1$.

5 Experimentos

Alguns experimentos foram realizados com o objetivo de avaliar o desempenho dos métodos de predição descritos anteriormente, em termos de velocidade de processamento e exatidão. Como mencionado anteriormente, os dados de entrada utilizados foram a componente estocástica das observações de irradiação solar. No entanto, a comparação final de exatidão dos resultados foi feita com os dados reais registrados, obtidos a partir da equação $I = I_{dt} + I_{st}$, conforme discutido na Seção 3.

A base de dados usada para treinamento e testes é composta de observações de irradiação registradas em intervalos de 30 minutos. Tanto a base de treinamento quanto a base de testes possuem cerca de um ano de observações, cada uma.

1. Dados de Treinamento:

de Abril - 2013 a Março - 2014

2. Dados de Teste:

de Abril - 2014 a Março - 2015




Figura 5: Valores observados nas medições de irradiação e valores retornados pelo método Persistência.




Figura 6: Valores observados nas medições de irradiação e valores retornados pelo método ELM.

Essa divisão resultou em 17.513 amostras de treinamento e 17.280 amostras para teste. A proposta de se utilizar um ano inteiro para testes foi avaliar o desempenho de predição sob diferentes condições climáticas.

Os dados de entrada para todos os métodos (exceto ARIMA, cujo formato de entrada foi discutido na seção que descreve o método) foram formatados em 6 observações sequenciais de irradiação solar. Em outras palavras, dada uma observação corrente t , os dados de entrada foram constituídos das observações registradas no intervalo de $t - 5$ a t , com o objetivo de prever o valor futuro $t + 1$. No caso do modelo ELM, outro parâmetro adotado foi o valor de 12 neurônios para a camada escondida da rede. As Figuras 5, 6, 7 e 8 ilustram os valores calculados pelos métodos de predição avaliados neste trabalho em comparação com os dados medidos em um dia de observações de irradiação. O dia utilizado foi 02 de abril de 2014, que faz parte da base utilizada para testes.

O modelo ELM possui em seu algoritmo de treinamento uma componente aleatória. Uma vez




Figura 7: Valores observados nas medi  es de irradia  o e valores retornados pelo m todo kNN.




Figura 8: Valores observados nas medi  es de irradia  o e valores retornados pelo m todo ARIMA.

que essa caracter stica pode influenciar no resultado final, o modelo foi executado 30 vezes e o resultado final registrado a seguir foi gerado a partir de uma m dia de todas as execu  es. Al m disso o desvio padr o para os resultados tamb m foi apresentado.

As m tricas escolhidas para avaliar a exatid o dos m todos foram a Raiz Quadrada do Erro M dio Quadr tico (*Root Mean Square Error - RMSE*) e sua vers o normalizada (*nRMSE*). Ambas s o descritas nas equa  es abaixo:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (I_t - \hat{I}_t)^2} \quad (15)$$

$$nRMSE = \sqrt{\frac{\sum_{t=1}^n (I_t - \hat{I}_t)^2}{\sum_{t=1}^n \hat{I}_t^2}} \quad (16)$$

As Tabelas 1 e 2 demonstram os resultados agrupados por m s da predi  o em termos de acur cia para os m todos analisados. Nos resultados, dois modelos obtiveram os melhores resultados:

kNN e ELM, sendo este  ltimo ligeiramente superior em alguns meses avaliados. Outro aspecto a se destacar foi o bom desempenho do modelo de Persist ncia, que a princ pio foi usado como refer ncia para os demais modelos. Tal situa  o pode ser explicada por cen rios em que h  pouca altera  o clim tica. O modelo ARIMA teve pior desempenho dentre os avaliados, o que sugere que, para que este consiga contemplar melhor as s ries temporais em an lise, possa ser necess ria a incorpora  o de uma componente que consiga modelar mais adequadamente a sazonalidade associada ao problema. O kNN, por sua vez, teve um desempenho acima do modelo de refer ncia, mas ainda inferior ao ELM. Um ponto a ser destacado neste modelo   a aus ncia de uma etapa de treinamento, o que em um primeiro momento pode ser observado como uma vantagem. A longo prazo, no entanto, em um contexto de altera  es nos padr es clim ticos vigentes, o modelo pode encontrar problemas para realizar uma eventual readapta  o.

Tabela 1: Erro de Predi  o - RMSE.

RMSE				
M�s	Persistence	ARIMA	kNN	ELM
2014-04	84.7667	92.2204	80.6711	79.7529 ± 0.2564
2014-05	80.1549	93.6016	79.1877	76.4931 ± 0.6512
2014-06	66.0692	70.4749	64.2329	60.6537 ± 0.2723
2014-07	74.7301	78.2315	72.4574	69.3097 ± 0.2850
2014-08	81.9827	83.0472	78.5713	75.6961 ± 0.2094
2014-09	64.5804	81.2112	67.1694	62.4151 ± 0.3093
2014-10	73.1025	85.8366	70.2621	68.8848 ± 0.3145
2014-11	88.9649	86.4535	78.1195	76.1150 ± 0.2844
2014-12	78.2640	88.9237	76.4641	74.9684 ± 0.3761
2015-01	80.3508	78.6993	76.0221	76.2232 ± 0.3073
2015-02	71.8613	74.4020	69.3758	68.3714 ± 0.2315
2015-03	82.9459	83.0699	80.4487	78.1325 ± 0.3205

Tabela 2: Erro de Predi  o Normalizado - nRMSE.

nRMSE (%)				
M�s	Persistence	ARIMA	kNN	ELM
2014-04	26.0970	28.3981	24.8361	24.5534 ± 0.0789
2014-05	25.2920	29.5008	24.9868	24.1365 ± 0.2055
2014-06	20.4130	21.9464	19.8457	18.7398 ± 0.0841
2014-07	24.2044	25.6209	23.4683	22.4488 ± 0.0923
2014-08	28.0606	28.5605	26.8930	25.9088 ± 0.0717
2014-09	17.9420	22.8274	18.6613	17.3404 ± 0.0859
2014-10	22.2266	26.0694	21.3630	20.9442 ± 0.0956
2014-11	31.2467	30.0230	27.4375	26.7335 ± 0.0999
2014-12	28.2985	31.9184	27.6477	27.1069 ± 0.1360
2015-01	23.9825	23.2046	22.6905	22.7506 ± 0.0917
2015-02	20.2438	21.1003	19.5436	19.2607 ± 0.0652
2015-03	24.5532	24.7428	23.8140	23.1283 ± 0.0949

Durante os experimentos, outro aspecto tamb m avaliado foi o tempo de processamento dos m todos durante treinamento e testes. As Tabelas 3 e 4 apresentam os resultados. Para o m todo ARIMA, a etapa de treinamento corresponde   etapa de estimativa dos par metros, realizada atrav s do m todo de M xima Verossimilhan a. N o h  etapa de treinamento para o m todo kNN. Sobre os resultados das Tabelas 3 e 4, h  de se destacar a boa velocidade de processamento do ELM nas fases de treinamento e teste, o que sugere uma

viabilidade de se incorporar a ele uma etapa de treinamento posterior (durante as execu  es) sem um preju zo ao desempenho do sistema como um todo.

Tabela 3: *Tempo de Treinamento em segundos.*

Tempo de Treinamento		
ARIMA	kNN	ELM
38.6510	-	8.2736

Tabela 4: *Tempo m dio de teste em segundos.*

Tempo de Teste		
ARIMA	kNN	ELM
0.2410	0.1652	0.0113

6 Conclus o e Trabalhos Futuros

Os resultados avaliados refor am a expectativa inicial de um melhor desempenho para o modelo de M quinas de Aprendizado Extremo, por este possuir uma maior capacidade de adequa  o a padr es mais complexos. No entanto, h  ainda pontos de melhoria que podem ser avaliados. Um ponto seria a observa  o de outras vari veis clim ticas, seguido de um estudo da rela  o entre elas e os valores de irradia  o solar. Al m disso, outra quest o a ser estudada seria a rela  o entre os valores de irradia  o solar observados em diferentes esta  es de um mesmo sistema, se analisados em fun  o do tempo e localiza  o geogr fica. Nesse contexto, altera  es mais agudas em determinadas esta  es poderiam indicar um pren ncio de varia  es de porte similar em outras esta  es vizinhas. A expectativa   de que essa avalia  o de novas vari veis possa trazer uma maior robustez para o modelo em an lise.

Agradecimentos

O presente trabalho foi realizado com o apoio do Instituto Federal de Minas Gerais - *campus* Sabar .

Refer ncias

- Box, G., Jenkins, G. and Reinsel, G. (2008). *Time Series Analysis: Forecasting and Control, fourth ed.*, Wiley.
- Charytoniuk, W. and Chen, M.-S. (2000). Very short-term load forecasting using artificial neural networks, *IEEE transactions on Power Systems* **15**(1): 263–268.
- Huang, G. B., Zhu, Q. Y. and Siew, C. K. (2006). Extreme learning machine: theory and applications, *Neurocomputing* **70**(1-3): 489–501.
- IEA (2014). Trends 2014 in photovoltaic applications - survey report of selected iea countries between 1992 and 2013, *Technical report*, International Energy Agency.
- Mellit, A. and Pavan, A. M. (2010). A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy, *Solar Energy* **84**(5): 807–821.
- Nobre, A. M. (2015). *Short-term solar irradiance forecasting and photovoltaic systems performance in a tropical climate in Singapore*, PhD thesis, Federal University of Santa Catarina, Brazil.
- Pedro, H. T. C. and Coimbra, C. F. M. (2012). Assessment of forecasting techniques for solar power production with no exogenous inputs, *Solar Energy* **86**(7): 2017–2028.
- Raza, M. Q. and Khosravi, A. (2015). A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings, *Renewable and Sustainable Energy Reviews* **50**: 1352–1372.
- Taylor, J. W. (2008). An evaluation of methods for very short-term load forecasting using minute-by-minute british data, *International Journal of Forecasting* **24**(4): 645 – 658. Energy Forecasting.
- Zhang, P. G. and Qi, M. (2005). Neural network forecasting for seasonal and trend time series, *European Journal of Operational Research* **160**: 501–514.