

# RESULTADOS PRELIMINARES DE PREVISÃO DE IRRADIAÇÃO SOLAR DE CURTO PRAZO ATRAVÉS DA COMBINAÇÃO DE PROCESSAMENTO DE IMAGENS COM ALGORITMOS DE APRENDIZAGEM DE MÁQUINA

Felipe Pinto Marinho – fpmarinho@alu.ufc.br  
Paulo Alexandre Costa Rocha – paulo.rocha@ufc.br  
Maria Eugênia Vieira da Silva – eugenia@ufc.br  
Ricardo José Pontes Lima – rjponteslima@gmail.com  
Juarez Pompeu de Amorim Neto – juarezneto33@hotmail.com  
Universidade Federal do Ceará, Departamento de Engenharia Mecânica

## 1. Radiação Solar

**Resumo.** Previsões de irradiação solar global de curto prazo no horizonte de previsão de 30 minutos a posteriori foram obtidas por meio da aplicação de algoritmos de aprendizagem de máquina em conjuntos de dados constituídos por sinais coletados por sensores de resistência dependente da luz e descritores estatísticos (média, desvio padrão e entropia de Shannon) extraídos de imagens do céu capturadas por uma câmera. A integração de tais sensores é feita por meio do Raspberry Pi 3, um computador que tem o tamanho de um cartão usado principalmente em projetos de programação, robótica e em iniciativas em geral com software e hardware livre. Desta forma, foi possível avaliar se a adição de preditores obtidos de imagens do céu proporcionam melhorias no desempenho dos modelos de aprendizagem de máquina utilizados, a saber: *Árvore de decisão com um procedimento de Bagging*, *Florestas Aleatórias* e *K-Vizinhos Mais Próximos*. Além disso, também foi avaliado se o uso dos filtros de suavização da mediana e o de aguçamento do laplaciano da gaussiana nas imagens ocasiona melhoras no desempenho relativo ao caso em que se obtém os descritores estatísticos das imagens sem a aplicação de nenhum filtro. A acurácia dos métodos é determinada pelo cálculo das métricas de erro Erro Médio Absoluto, Raiz do Erro Quadrático Médio, Raiz do Erro Quadrático Médio Relativo e a Habilidade de Previsão. A média aritmética da Raiz do Erro Quadrático Médio para os modelos quando se considerou como atributos apenas o valores fornecidos pelos sensores de luminosidade foi de  $165,49 \text{ W/m}^2$ , já para o caso em que se adiciona informações das imagens não filtradas obteve-se  $154,01 \text{ W/m}^2$ , para o caso de se adicionar informações de imagens filtradas pelo filtro da mediana teve-se um valor de  $153,69 \text{ W/m}^2$ , por fim, para o outro filtro obteve-se  $162,24 \text{ W/m}^2$ .

**Palavras-chave:** Energia Solar, Aprendizagem de Máquina, Processamento Digital de Imagens

## 1. INTRODUÇÃO

O potencial de inserção de energias renováveis na matriz energética global, em especial da energia solar, torna necessária uma adequada gestão de fornecimento de energia pelo órgão de controle, uma vez que se tratam de fontes com comportamento estocástico e intermitente. Ter uma previsão confiável da irradiação solar futura na região de um parque solar permite ao operador da rede elétrica avaliar em que momentos serão necessárias complementações do abastecimento com outras fontes.

O operador da rede precisa de previsões confiáveis em diferente horizontes temporais, aquela feitas em intervalos de horas e minutos são adequadas para prever quedas de fornecimento, enquanto as realizadas em intervalos de dias se destacam na programação de manutenções preventivas. Problemas relacionados à flutuação de tensão, qualidade de energia e estabilidade da rede elétrica podem ser evitados por meio da realização de previsões de irradiação solar.

Neste sentido, muitas metodologias têm sido utilizadas para que previsões de irradiação em diferentes horizontes de tempo sejam efetuadas. Uso de modelos *Numerical Weather Prediction (NWP)* (Mejia *et al.*, 2018; Nonnemacher *et al.*, 2016), análise de séries temporais (Trapero *et al.*, 2015; Dong *et al.*, 2013), aplicações envolvendo processamento de imagens (Pedro *et al.*, 2018; Pedro *et al.*, 2015; Pawar *et al.*, 2019) e utilização de algoritmos de aprendizagem de máquina (Koo *et al.*, 2019; Yagli *et al.*, 2019; Benali *et al.*, 2019) destacam-se como abordagens comumente aplicadas para a obtenção de previsões de irradiação solar.

No estudo desenvolvido, realizou-se previsões de irradiação solar global para o horizonte de 30 minutos a posteriori por meio da aplicação de modelos de aprendizagem de máquina em quatro conjuntos de dados:

- Conjunto I: Um formado por atributos que correspondem a sinais obtidos por sensores de resistência dependente da luz (LDR's), onde foram utilizados quatro LDR's. Além disso, considerou-se a irradiação do instante atual como um preditor. Desta forma, o conjunto de dados ficou com 5 atributos e 1466 observações;

- Conjunto II: Formado pelos atributos do conjunto anterior, adicionado de descritores estatísticos (média, desvio padrão e entropia de Shannon) para os canais vermelho, verde e azul de imagens do céu, totalizando 14 atributos e 1466 observações;
- Conjunto III: Formado pelos atributos do primeiro conjunto de dados adicionado de descritores estatísticos (média, desvio padrão e entropia de Shannon) extraídos de imagens do céu em tons de cinza filtradas pela aplicação do filtro de suavização da mediana, assim totalizando 8 atributos e 1466 observações;
- Conjunto IV: Formado pelos atributos do primeiro conjunto de dados adicionado de descritores estatísticos (média, desvio padrão e entropia de Shannon) extraídos de imagens do céu em tons de cinza filtradas pela aplicação do filtro de aguçamento do laplaciano da gaussiana, assim totalizando 8 atributos e 1466 observações.

O objetivo é o de avaliar se a adição de atributos relacionados à imagens do céu, bem como se o uso de determinados filtros digitais (mediana e laplaciano da gaussiana) nas imagens proporcionam uma melhora na acurácia dos algoritmos de aprendizagem de máquina utilizados, a saber: K-Vizinhos Mais Próximos (KNN), uma árvore de decisão com a aplicação de um procedimento de *Bagging* e o algoritmo de Florestas Aleatórias (RF). A avaliação do desempenho é feita por meio do cálculo das métricas Erro Médio Absoluto (MAE), Raiz do Erro Quadrático Médio (RMSE), Raiz do Erro Quadrático Médio Relativo (rRMSE) e a Habilidade de Previsão (s). O restante do artigo é formado pela seção 2 que trata da forma de aquisição dos dados, além de abordar sobre o procedimento aplicado para a realização do treinamento dos algoritmos. Na seção 3 os modelos aplicados são detalhados, além de se ter uma pequena apresentação dos descritores estatísticos, dos filtros espaciais aplicados e das métricas de erro utilizadas. Posteriormente, na seção 4, tem-se a apresentação dos resultados e, por fim, a seção 5 ilustra as conclusões obtidas.

## 2. DADOS

Os dados foram coletados no Laboratório de Energia Solar e Gás Natural (LESGN) do Centro de Tecnologia da Universidade Federal do Ceará, na cidade de Fortaleza-CE, Brasil  $3^{\circ}43'6''S$  e  $38^{\circ}32'36''O$  entre os dias 03/06/2019 à 07/06/2019, caracterizados por serem dias de céu claro com baixa nebulosidade, englobando o intervalo de 8:00 às 17:30. Os sensores LDR's e a câmera foram integrados por meio do uso de um Raspberry Pi 3, um computador que tem o tamanho de um cartão usado principalmente em projetos de programação, robótica e em iniciativas em geral com software e hardware livres. O sistema de aquisição já montado é representado na Fig. 1, onde o número 1 indica os LDR's e o 2 a câmera.

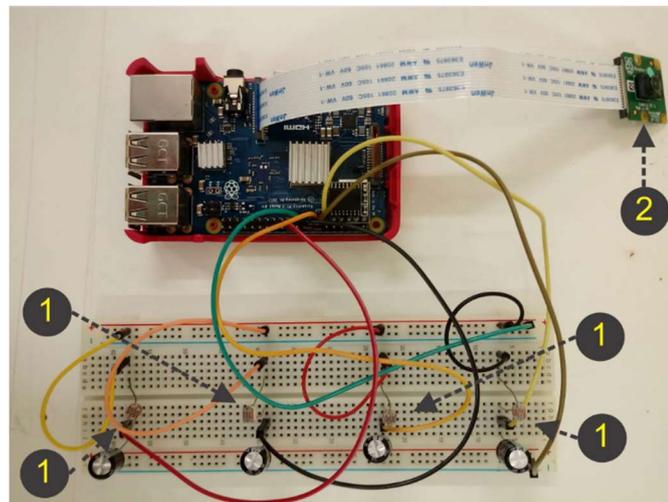


Figura 1 – Sistema de aquisição montado

Para o treinamento dos modelos, os conjuntos de dados foram divididos aleatoriamente de tal forma que 70% ficou para o treinamento dos algoritmos e o restante formou o conjunto de validação. O ajuste dos métodos foi feito por meio da aplicação de validação cruzada 10-Fold (James *et al.*, 2013). Esta etapa de treinamento é representada pela Fig. 2.

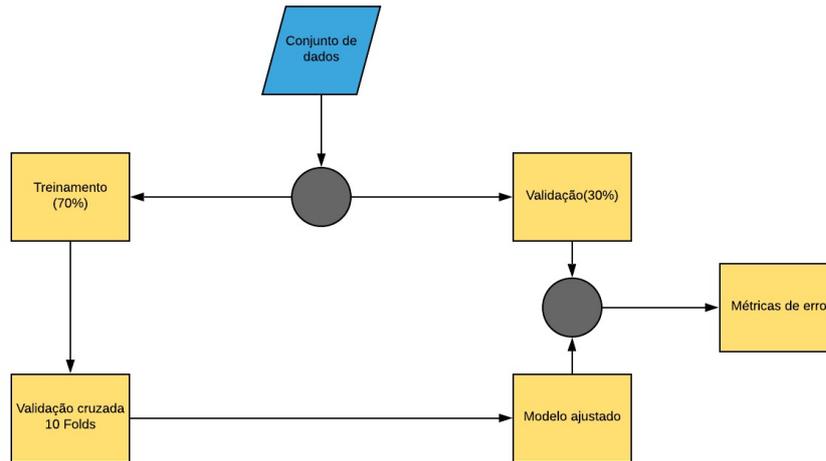


Figura 2 – Representação da etapa de treinamento

### 3. METODOLOGIA

#### 3.1 Modelo de baseline

O modelo de baseline escolhido atribui para uma nova observação a irradiação média do conjunto de treinamento (Hyndman e Athanasopoulos, 2018). Seja  $T = \{G_1, G_2, \dots, G_n\}$  os valores de irradiação do conjunto de treinamento. Desta forma, o valor atribuído para uma nova observação é dado pela Eq. (1).

$$G = \frac{\sum_{i=1}^n G_i}{n} \quad (1)$$

Funciona como um modelo que fornece um desempenho mínimo, atuando como uma cota inferior para a acurácia dos demais métodos utilizados. Espera-se que o mesmo forneça os maiores valores para as métricas de erro RMSE e MAE.

#### 3.2 Árvore de decisão com a aplicação de um procedimento de bagging

As árvores de decisão envolvem a segmentação do espaço de atributos por meio da aplicação de regras, as quais podem ser resumidas em um formato de árvore, proporcionando o desenvolvimento de métodos simples e de fácil interpretação. Entretanto, estas tipicamente não são competitivas quando se compara sua acurácia de previsão com as de outros modelos clássicos de aprendizagem supervisionada. Desta forma, existem algumas abordagens que envolvem a formação de múltiplas árvores que são combinadas para conduzir a uma única previsão, algo similar ao que ocorre nas máquinas de comitê. Tal combinação pode resultar em melhorias significativas na acurácia de previsão, mas com uma perda na capacidade de interpretação (James *et al.*, 2013). Uma destas metodologias de combinação de árvores é o Bootstrap Aggregation (*Bagging*), que é um método *Ensemble* que combina as saídas de múltiplos algoritmos de aprendizagem de máquina em um único valor. Esta metodologia é geralmente utilizada com o intuito de redução da variância de modelos de alta variância, como os das árvores de decisão (James *et al.*, 2013; Kuhn e Johnson, 2013). O primeiro passo neste procedimento é a realização de um *Bootstrap* no conjunto de dados considerado, que consiste na formação de várias amostras através da realização de múltiplas amostragens com reposição no conjunto de dados original. Posteriormente, para cada amostra desenvolve-se uma árvore de decisão e, por fim, as saídas resultantes de cada árvore serão combinadas por uma média aritmética para a obtenção do resultado final. Todo este procedimento está representado na Fig. 3.

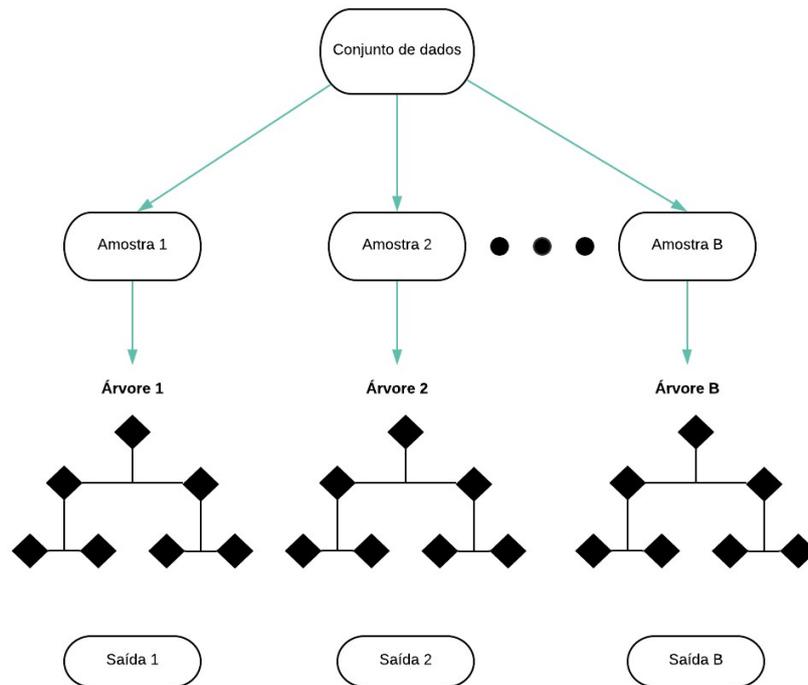


Figura 3 – Representação esquemática de um *Bagging* aplicado em árvores de decisão

Onde tem-se o vetor  $O = \{Saída\ 1, Saída\ 2, \dots, Saída\ B\} = \{f_1^*(x), f_2^*(x), \dots, f_B^*(x)\}$ . Desta forma, a saída resultante do *Bagging* será dada pela Eq. (2).

$$f^*(x) = \frac{\sum_{i=1}^B f_i^*(x)}{B} \quad (2)$$

Neste caso, percebe-se que o único hiperparâmetro presente neste método é o número de árvores considerada, tal parâmetro não é crítico uma vez que um valor elevado de árvores não irá conduzir a problemas relacionados à overfitting (James *et al.*, 2013). Entretanto, um número exagerado pode proporcionar um alto tempo de processamento. Neste trabalho, para todos os conjuntos de dados foram utilizadas 500 árvores, que foi o valor que proporcionou um melhor balanceamento entre desempenho e tempo computacional.

### 3.3 Florestas aleatórias

O algoritmo de Florestas Aleatórias é análogo ao *Bagging*, mas com o uso de uma pequena modificação visando descorrelacionar as árvores (James *et al.*, 2013). Uma vez que, no *Bagging* para cada amostra ocorre o desenvolvimento de uma árvore por meio da segmentação do mesmo espaço de preditores, este procedimento tende a ocasionar a obtenção de respostas que apresentam um elevado grau de correlação, mas em algumas situações, combinações de previsões de vários modelos fornecem melhores resultados quando as saídas dos sub-modelos são descorrelacionadas ou na melhor das hipóteses apresentam nível fraco de correlação. Basicamente, a proposta deste algoritmo é a de que para a formação de cada árvore seja feita a divisão do espaço de  $m$  preditores selecionados aleatoriamente de um total de  $p$  preditores, onde, tipicamente, seleciona-se  $m = \sqrt{p}$ . De fato, por meio do treinamento foi possível obter o valor  $m_{ótimo} = 6$ .

### 3.4 K-vizinhos mais próximos

Este conhecido método é geralmente aplicado em problemas de classificação, porém o mesmo admite uma versão no contexto de regressão, onde o algoritmo identifica os  $K$  vizinhos, que estão no conjunto de treinamento, mais próximos de uma nova observação por meio do uso de uma métrica de dissimilaridade. Neste trabalho utilizou-se a distância euclidiana, e atribui a média aritmética dos valores de irradiação de tais vizinhos. Neste caso, a irradiação estimada para uma nova observação será como na Eq. (3).

$$G = \frac{\sum_{i=1}^K G_i}{K} \quad (3)$$

Onde,  $G_i$ , com  $i = \{1, 2, \dots, K\}$  são as irradiações dos  $K$  vizinhos mais próximos. O número de vizinhos  $K$  é, portanto, o único hiperparâmetro deste modelo que no caso foi obtido na etapa de treinamento resultando em  $K_{ótimo} = 11$ .

### 3.5 Descritores estatísticos

Os descritores estatísticos utilizados foram a média aritmética, desvio padrão e entropia de Shannon, que foram extraídos das imagens coloridas para os canais RGB (vermelho, verde e azul). Estes são definidos pelas Eq. (4), Eq. (5) e Eq.(6), respectivamente.

$$\mu = \frac{\sum_{i=1}^N v_i}{N} \quad (4)$$

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (v_i - \mu)^2}{N}} \quad (5)$$

$$e = - \sum_{\substack{i=1 \\ p_i \neq 0}}^{N_B} p_i \log_2 p_i \quad (6)$$

Onde  $v_i$  representa as intensidades de cinza dos pixels em um dados canal,  $N$  o número total de pixels em um dado canal,  $p_i$  é a frequência relativa de um  $i$ -ésimo nível de cinza de um dado canal e  $N_B = 256$ . Uma vez que as imagens utilizadas neste trabalho são de 8-bits.

### 3.6 Filtro de suavização da mediana

Filtros de suavização ou filtros passa-baixa caracterizam-se por atenuarem regiões de alta frequência na imagem, regiões de alta variabilidade nas intensidades de cinza, tais como, ruídos e contornos. O aspecto geral proporcionado pela aplicação destas máscaras nas imagens é o borrimento das mesmas. O filtro de suavização da mediana atribui para os pixels da imagem filtrada a mediana dos níveis de cinza dos pixels englobados pela máscara e, de uma forma geral, aumentando o tamanho do kernel o nível de borrimento na imagem filtrada se torna mais acentuado, como ilustra a Fig. 4 para a aplicação do filtro da mediana com kernels quadrados de tamanho 3, 5, 7, 9 e 11 em uma imagem utilizada neste trabalho. Como se pode notar pela Fig. 4, de fato um filtro de suavização atenua regiões de alta frequência, como se observa pelo artefato metálico que basicamente desaparece quando se intensifica o efeito do filtro da mediana pelo aumento da dimensão de sua máscara. O tamanho das máscaras aplicadas tanto para o filtro da mediana como o do laplaciano da gaussiana neste trabalho foi de  $5 \times 5$ , pois esta dimensão foi a que proporcionou um melhor impacto sobre as imagens sem que houvesse grande perda de informação relativa à imagem original.



Figura 4 – (a) Imagem original, (b) Imagem filtrada com mediana de tamanho 3, (c) Imagem filtrada com mediana de tamanho 5, (d) Imagem filtrada com mediana de tamanho 7, (e) Imagem filtrada com mediana de tamanho 9 e (f) Imagem com mediana de tamanho 11.

### 3.7 Filtro de aguçamento do laplaciano da gaussiana

Filtros de aguçamento ou filtros passa-alta apresentam uma funcionalidade contrária aos filtros de suavização. Neste caso, tem-se uma atenuação nas regiões de baixa frequência, regiões de pequena variabilidade nos tons de cinza dos pixels, e um realce de regiões de alta frequência. Estes filtros são muito utilizados para propósitos de detecção de bordas. Neste estudo considerou-se o filtro de aguçamento do laplaciano da gaussiana (LoG) cuja máscara é obtida pela aplicação do operador laplaciano na função gaussiana bidimensional que pela omissão do fator de escala é representada pela Eq. (7).

$$\nabla^2 g(x, y) = \frac{x^2 + y^2 - 2\sigma^2}{\sigma^4} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (7)$$

A principal diferença deste filtro para os demais filtros de aguçamento é que o mesmo apresenta uma etapa de suavização anterior ao realce da alta frequência, evitando a intensificação de ruídos que possam estar presentes na imagem original. Para ilustrar o efeito da aplicação deste filtro como um método de detecção de bordas, a Fig. 5 mostra uma imagem deste trabalho processada com o filtro do laplaciano da gaussiana utilizando um kernel quadrado com dimensões 3, 5, 7, 9 e 11.

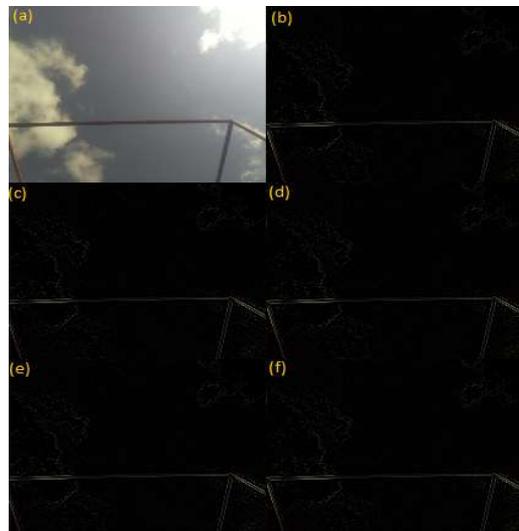


Figura 5 – (a) Imagem original, (b) Imagem filtrada com LoG de tamanho 3, (c) Imagem filtrada com LoG de tamanho 5, (d) Imagem filtrada com LoG de tamanho 7, (e) Imagem filtrada com LoG de tamanho 9 e (f) Imagem filtrada com LoG de tamanho 11

### 3.8 Métricas de erro

As métricas de erro utilizadas para realizar a avaliação do desempenho dos modelos de aprendizagem de máquina utilizados são apresentadas nesta seção.

**Erro médio absoluto.** O MAE calcula a média das diferenças absolutas entre o valor previsto,  $\hat{y}_i$ , e o valor real,  $y_i$ , isso é, não leva em consideração se o erro é para mais ou para menos e às diferenças absolutas não é atribuído peso, como indica a Eq. (8).

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (8)$$

**Erro quadrático médio.** O RMSE calcula a magnitude da média do erro pela raiz quadrada da média dos quadrados dos erros. Desse modo atribui um peso maior aos erros de maior magnitude, e peso menor aos erros de menor magnitude. É obtido na mesma unidade da variável em análise, sendo definida pela Eq. (9).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (9)$$

**Erro quadrático médio relativo.** O  $rRMSE$  é a razão entre o  $RMSE$  e a média dos valores da variável em análise, como dado pela Eq. (10).

$$rRMSE = \frac{\sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}}{\frac{\sum_{i=1}^n y_i}{n}} \quad (10)$$

Tal métrica foi utilizada porque fornece faixas de classificação do desempenho das previsões:  $rRMSE < 10\%$  excelente,  $10\% < rRMSE < 20\%$  bom,  $20\% < rRMSE < 30\%$  razoável,  $rRMSE > 30\%$  ruim (Li *et al.*, 2013).

**Habilidade de previsão.** Esta métrica avalia o desempenho do modelo aplicado quando comparado com a acurácia do modelo de baseline, sendo definido pela Eq. (11).

$$s = 1 - \frac{RMSE}{RMSE_B} \quad (11)$$

Onde o  $RMSE$  representa a o valor da métrica de erro para o modelo em análise e o  $RMSE_B$  representa o valor da métrica de erro para o modelo de baseline.

#### 4. RESULTADOS

Os resultados são reportados nas Tab. 1, Tab. 2, Tab. 3 e Tab. 4 para a aplicação dos modelos de aprendizagem da máquina sobre os conjuntos I, II, III e IV, respectivamente.

Tabela 1 – Resultados para o conjunto I

Métodos	Conjunto de Treinamento				Conjunto de Validação			
	MAE (W/m <sup>2</sup> )	RMSE (W/m <sup>2</sup> )	rRMSE (%)	s (%)	MAE (W/m <sup>2</sup> )	RMSE (W/m <sup>2</sup> )	rRMSE (%)	s (%)
Baseline	-	-	-	-	233,49	274,15	45,33	0
Bagging	115,07	158,92	26,70	39,37	121,57	170,75	28,23	37,72
RF	46,33	70,37	12,04	74,33	103,72	156,35	25,85	42,97
KNN	93,22	142,34	24,36	48,08	111,71	169,36	28,01	38,22

Tabela 2 – Resultados para o conjunto II

Métodos	Conjunto de Treinamento				Conjunto de Validação			
	MAE (W/m <sup>2</sup> )	RMSE (W/m <sup>2</sup> )	rRMSE (%)	s (%)	MAE (W/m <sup>2</sup> )	RMSE (W/m <sup>2</sup> )	rRMSE (%)	s (%)
Baseline	-	-	-	-	233,49	274,15	45,33	0
Bagging	109,78	150,69	25,79	45,04	115,39	159,99	26,46	41,64
RF	41,07	62,30	10,66	77,27	98,26	147,82	24,44	46,08
KNN	98,41	146,19	25,02	46,68	104,93	154,23	25,50	43,74

Tabela 3 – Resultados para o conjunto III

Métodos	Conjunto de Treinamento				Conjunto de Validação			
	MAE (W/m <sup>2</sup> )	RMSE (W/m <sup>2</sup> )	rRMSE (%)	s (%)	MAE (W/m <sup>2</sup> )	RMSE (W/m <sup>2</sup> )	rRMSE (%)	s (%)
Baseline	-	-	-	-	233,49	274,15	45,33	0
Bagging	109,27	150,79	25,81	45,00	114,24	158,55	26,22	42,17
RF	43,00	65,14	11,15	76,23	97,24	145,17	24,00	47,05
KNN	89,96	136,60	23,38	50,17	103,95	157,36	26,02	42,60

Tabela 4 – Resultados para o conjunto IV

Métodos	Conjunto de Treinamento				Conjunto de Validação			
	MAE (W/m <sup>2</sup> )	RMSE (W/m <sup>2</sup> )	rRMSE (%)	s (%)	MAE (W/m <sup>2</sup> )	RMSE (W/m <sup>2</sup> )	rRMSE (%)	s (%)
Baseline	-	-	-	-	233,49	274,15	45,33	0
Bagging	111,80	154,10	26,37	43,79	118,38	168,16	27,80	38,66
RF	49,65	72,33	12,38	73,62	105,00	155,44	25,70	43,30
KNN	94,64	143,49	24,56	47,66	108,28	163,11	26,97	40,50

Pela avaliação dos resultados e comparando com aqueles encontrados em alguns trabalhos que utilizam metodologias similares (Pedro *et al.*, 2018; Pedro *et al.*, 2015) percebe-se que preditores relacionados a sinais de LDR's não conseguem capturar de forma adequada o comportamento da irradiação solar. Isto se deve a uma falta de sensibilidade dos sensores LDR's. Em casos de início e fim de dia os valores de irradiação solar sofrem uma redução significativa, enquanto os valores reportados pelos sensores de luminosidade não acompanham esse decréscimo. Possíveis soluções para este problema seriam a realização de alterações no circuito elétrico, como a adição de potenciômetros e/ou adicionar filtros ópticos na tentativa de aumentar a sensibilidade dos sensores LDR's.

Outro fator relevante que teve forte influência para a obtenção destes resultados foi que considerou-se apenas o valor de irradiação solar do instante atual como preditor. Entretanto, condições climáticas locais favorecem o desenvolvimento de séries temporais de irradiação solar que são fortemente autocorrelacionadas (Inman *et al.*, 2013). Assim, uma boa estratégia para incrementar a acurácia das previsões seria a adição de preditores relacionados a valores de irradiação de instantes passados.

Observando os resultados percebe-se também que a introdução de descritores estatísticos extraídos das imagens como preditores para os algoritmos, trouxe melhorias nos resultados para todos os métodos considerados. Esta conclusão está em concordância com aquelas encontradas em trabalhos recentes (Pedro *et al.*, 2018; Pedro *et al.*, 2015). De fato, a introdução de informações relacionadas à imagens do céu contribui para uma melhor generalização dos algoritmos e acredita-se que a introdução de novos atributos extraídos destas imagens irá contribuir para um acréscimo ainda mais significativo no desempenho dos modelos. Para estudos posteriores, pretende-se utilizar valores de energia dos coeficientes wavelets obtidos pela decomposição das imagens por meio do uso da transformada wavelet Haar como preditores para os modelos.

Os resultados para a aplicação dos filtros indicam que a filtragem pelo kernel da mediana não altera significativamente a acurácia dos métodos quando se compara com o caso em que não há filtragem. Esta mudança pode ser positiva ou negativa, mas no geral não é abrupta. Um comportamento geral percebido foi a melhora no desempenho do algoritmo de Florestas Aleatórias. Desta forma, percebe-se que tal modelo é mais sensível aos atributos obtidos das imagens e que a atenuação de ruídos nas imagens contribui positivamente para a acurácia deste método. Para o kernel LoG houve uma piora no desempenho dos modelos quando comparado com o caso em que não se teve a filtragem. A razão para o uso deste filtro foi a de que o mesmo atua como um detector de bordas, assim haveria a possibilidade de identificar a ocorrência de nuvens, que é uma das principais razões para o caráter intermitente da irradiação solar. Acreditava-se que esta informação seria útil para a aprendizagem dos modelos, o que ainda não se provou verdade.

## 5. CONCLUSÃO

No trabalho em questão realizou-se a previsão de irradiação solar de curto prazo para um horizonte de previsão de 30 minutos a posteriori pela aplicação de modelos de aprendizagem de máquina, a saber: Árvore de decisão com aplicação de um procedimento de Bagging, Florestas Aleatórias e K-vizinhos mais próximos, em quatro conjuntos de dados constituídos por atributos obtidos por quatro sensores LDR's e uma câmera que capturou imagens do céu, tais sensores foram integrados por meio do uso de um Raspberry Pi 3. Os resultados indicam que o uso de sinais de sensores LDR's como os únicos preditores de um conjunto de dados não fornecem uma boa representação do efeito estocástico da irradiação solar, observou-se também que a adição de descritores estatísticos, extraídos das imagens do céu, no conjunto de dados como atributos proporcionam melhorias consideráveis nos desempenhos dos modelos utilizados. Esta melhora é observada tanto no caso de imagens não filtradas como no caso em que as mesmas são filtradas. O uso do filtro da mediana proporcionou melhoras nos desempenhos dos modelos de árvore com Bagging e o das Florestas Aleatórias, mas piorou a acurácia do KNN, além disso, o filtro LoG não contribuiu para uma melhor generalização dos algoritmos.

### Agradecimentos

Este estudo foi financiado em parte pela Coordenação para o Aperfeiçoamento de Pessoal de Ensino Superior - Brasil (CAPES) – Código Financeiro 001, e pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), órgãos governamentais brasileiros. O suporte recebido é reconhecido com gratidão.

## REFERÊNCIAS

- Benali, L. *et al.*, 2019. Solar radiation forecasting using artificial neural network and random forest methods: Application to normal beam, horizontal diffuse and global components. *Renewable energy*, vol. 132, pp. 871-884.
- Dong, Z. *et al.*, 2013. Short-term solar irradiance forecasting using exponential smoothing state space model. *Energy*, vol. 55, pp. 1104-1113.
- Hyndman, R. J., Athanasopoulos, G., 2018. *Forecasting: principles and practice*, OTexts.
- Inman, R. H., Pedro, H.T.C., Coimbra, C.F.M., 2013. Solar forecasting methods for renewable energy integration. *Progress in energy and combustion science*, vol. 39, n. 6, pp. 535-576.
- James, G. *et al.*, 2013. *An Introduction to Statistical Learning*, Springer.
- Koo, C. *et al.*, 2019. A novel estimation approach for the solar radiation potential with its complex spatial pattern via machine-learning techniques. *Renewable energy*, vol. 133, pp. 575-592.
- Kuhn, M., Johnson, K, 2013. *Applied predictive modeling*, Springer.
- Mejia, J. F., Giordano, M., Wilcox, E, 2018. Conditional summertime day-ahead solar irradiance forecast. *Solar Energy*, vol. 163, pp. 610-622.
- Nonnenmacher, L., Kaur, A., Coimbra, C. F. M., 2016. Day-ahead resource forecasting for concentrated solar power integration. *Renewable energy*, vol. 86, pp. 866-876.
- Pawar, P. *et al.*, 2019. Detecting clear sky images. *Solar Energy*, vol. 183, pp. 50-56.
- Pedro, H. T. C., Coimbra, C. F. M., 2015. Nearest-neighbor methodology for prediction of intra-hour global horizontal and direct normal irradiances. *Renewable Energy*, vol. 80, pp. 770-782.
- Pedro, H. T. C *et al.*, 2018. Assessment of machine learning techniques for deterministic and probabilistic intra-hour solar forecasts. *Renewable Energy*, vol. 123, pp. 191-203.
- Trapero, J. R., Kourentzes, N., Martin, A., 2015. Short-term solar irradiation forecasting based on dynamic harmonic regression. *Energy*, vol. 84, pp. 289-295.
- Yagli, G. M., Yang, D., Srinivasan, D., 2019. Automatic hourly solar forecasting using machine learning models. *Renewable and Sustainable Energy Reviews*, vol. 105, pp. 487-498.

## PRELIMINARY RESULTS OF SHORT-TERM SOLAR IRRADIATION FORECASTING THROUGH IMAGE PROCESSING COMBINATION WITH MACHINE LEARNING ALGORITHMS

**Abstract.** *Short-term global solar irradiation forecasting over the 30-minute prediction horizon were obtained by applying machine learning algorithms to data sets consisting of signals collected by light-dependent resistance sensors and statistical descriptors (mean, standard deviation and Shannon entropy) taken from sky images captured by a camera. The integration of such sensors is done through Raspberry Pi 3, a card-sized computer used primarily in programming projects, robotics, and general software and hardware initiatives. Thus, it was possible to evaluate if the addition of predictors obtained from sky images provide improvements in the performance of the machine learning models used, namely: Decision tree with a Bagging procedure, Random Forests and K-Nearest Neighbors. In addition, it was also evaluated whether the use of the median smoothing filters and the gaussian laplacian sharpening filters in the images cause improvements in the performance in which the statistical descriptors of the images are obtained without the application of any filter. The accuracy of the methods is determined by calculating the Error Mean Absolute Error, Root Mean Square Error, Relative Root Mean Square Error and Forecast Skill metrics. The arithmetic mean of the Root Mean Square Error for the models when considering as attributes only the values provided by the light sensors was  $165.49 \text{ W} / \text{m}^2$ , but for the case where information from unfiltered images is added, it was obtained  $154.01 \text{ W} / \text{m}^2$ , when adding information from images filtered by the median filter, a value of  $153.69 \text{ W} / \text{m}^2$  was obtained. Finally, for the other filter,  $162.24 \text{ W} / \text{m}^2$  was obtained.*

**Key words:** *Solar Energy, Machine Learning, Digital Image Processing*