Estimativa da irradiância local utilizando inteligência artificial

Rafael Martini Silva (Lactec) - rafael.martini@lactec.org.br

Gelson Luiz Carneiro (Lactec) - gelsonluiz@lactec.org.br

Carlos Ademar Purim (LACTEC) - purim@lactec.org.br

Vilson Rodrigo Mognon (Lactec) - vilson@lactec.org.br

Bruno MARCHESI (LACTEC) - bruno.marchesi@gmail.com

Eduardo Henrique Fideles Ribeiro (Lactec) - eduardo.ribeiro@lactec.org.br

Anderson Stonoga (Lactec) - anderson.stonoga@lactec.org.br

Cleber Onofre Inacio (PETROBRAS) - cleberoi@petrobras.com.br

Luiz Fernando Almeida Fontenele (PETROBRAS) - luizfernando.fontenele@gmail.com

Paulo Henrique Fernandes Ferreira (Petrobras) - phff@petrobras.com.br

Rodrigo Dias (Petrobras) - rodias@petrobras.com.br

Resumo:

Uma etapa fundamental para as análises de viabilidade de um empreendimento de energia solar, independentemente de seu porte, baseia-se na obtenção de uma estimativa da produção anual de energia. Assim, a estimativa da geração pode ser uma ferramenta aliada na busca por uma maior penetração das energias renováveis no sistema elétrico. Nessa linha, recentemente, vários trabalhos vêm sendo desenvolvidos com o objetivo de contribuir nas estimativas da disponibilidade de irradiância solar utilizando sistemas de Inteligência Artificial (IA). O presente trabalho apresenta as etapas iniciais do desenvolvimento de uma metodologia que emprega a visão computacional aliada à inteligência computacional, a fim de avaliar a disponibilidade de irradiância solar para locais de interesse, a partir da análise de imagens adquiridas do céu e de uma metodologia baseada em aprendizado de máquina. Dentro do contexto deste trabalho, modelos foram testados visando à estimativa da irradiância global com o objetivo de fazer uma avaliação prévia de seus desempenhos. Os resultados obtidos sugerem que a metodologia é promissora para aplicação na estimativa dos níveis de irradiância solar global e possibilidade de extensão para o cálculo de suas componentes difusa e direta, sem a necessidade de utilizar pireliômetro e rastreador solar ou anel de sombreamento, buscando disponibilizar uma alternativa de baixo custo para estimativas preliminares do recurso solar.

Palavras-chave: *Energia Solar, Inteligência Artificial, Visão Computacional*

Área temática: *Radiação Solar*

Subárea temática: *Recursos Solares e Meteorologia da Radiação Solar*

ESTIMATIVA DA IRRADIÂNCIA SOLAR LOCAL UTILIZANDO INTELIGÊNCIA ARTIFICIAL

Rafael Martini Silva – rafael.martini@lactec.org.br
Gelson Luiz Carneiro – gelsonluiz@lactec.org.br
Instituto de Tecnologia para o Desenvolvimento (LACTEC), Departamento de Sistemas Mecânicos
Carlos Ademar Purim – purim@lactec.org.br
Vilson Rodrigo Mognon – vilson@lactec.org.br
Bruno Marchesi – marchesi@lactec.org.br
Eduardo Henrique Fideles Ribeiro – eduardo.ribeiro@lactec.org.br
Anderson Stonoga – anderson.stonoga@lactec.org.br
Instituto de Tecnologia para o Desenvolvimento (LACTEC), Departamento de Eletrônica
Cleber Onofre Inácio – cleberoi@petrobras.com.br
Luiz Fernando Almeida Fontenele – luizfontenele@petrobras.com.br
Paulo Henrique Fernandes Ferreira – phff@petrobras.com.br
Rodrigo Dias – rodias@petrobras.com.br
Petróleo Brasileiro S.A. (PETROBRAS), Centro de Pesquisas e Desenvolvimento (CENPES)

Resumo. *Uma etapa fundamental para as análises de viabilidade de um empreendimento de energia solar, independentemente de seu porte, baseia-se na obtenção de uma estimativa da produção anual de energia. Assim, a estimativa da geração pode ser uma ferramenta aliada na busca por uma maior penetração das energias renováveis no sistema elétrico. Nessa linha, recentemente, vários trabalhos vêm sendo desenvolvidos com o objetivo de contribuir nas estimativas da disponibilidade de irradiância solar utilizando sistemas de Inteligência Artificial (IA). O presente trabalho apresenta as etapas iniciais do desenvolvimento de uma metodologia que emprega a visão computacional aliada à inteligência computacional, a fim de avaliar a disponibilidade de irradiância solar para locais de interesse, a partir da análise de imagens adquiridas do céu e de uma metodologia baseada em aprendizado de máquina. Dentro do contexto deste trabalho, modelos foram testados visando à estimativa da irradiância global com o objetivo de fazer uma avaliação prévia de seus desempenhos. Os resultados obtidos sugerem que a metodologia é promissora para aplicação na estimativa dos níveis de irradiância solar global e possibilidade de extensão para o cálculo de suas componentes difusa e direta, sem a necessidade de utilizar pireliômetro e rastreador solar ou anel de sombreamento, buscando disponibilizar uma alternativa de baixo custo para estimativas preliminares do recurso solar.*

Palavras-chave: *Energia Solar, Inteligência Artificial, Visão Computacional*

1 INTRODUÇÃO

O setor de energia solar vem experimentando um notório crescimento nos últimos anos no mundo e, mais recentemente, no Brasil. Como os dados ainda não estão consolidados a nível mundial, as estimativas apontam que, em 2019, o mundo encerrou o ano com uma potência fotovoltaica acumulada de 633 GW (*Renewable Energy Policy Network for the 21st Century* (REN21), 2019), (*Bloomberg New Energy Finance* (BNEF), 2020). Nesse mesmo ano, o país obteve uma potência fotovoltaica acumulada de 4,46 GW, sendo 2,47 GW referentes à geração centralizada e 1,99 GW à geração distribuída (Agência Nacional de Energia Elétrica (ANEEL), 2020a, 2020b).

Uma etapa fundamental para as análises de viabilidade de um empreendimento de energia solar, independentemente de seu porte, está na estimativa da produção anual de energia. Para tanto, é necessário fazer uma avaliação, ainda que preliminar, da disponibilidade do recurso solar em locais de interesse. Nesse contexto, no âmbito de P&D do sistema elétrico, regulado pela Agência Nacional de Energia Elétrica (ANEEL), a PETROBRAS iniciou em 2016 um projeto de pesquisa intitulado "Métodos de menor custo para prospecção e avaliação do potencial solar brasileiro" (PD-00553-0034/2016), com o intuito de disponibilizar metodologias e tecnologias de menor custo para levantamento e avaliação do recurso solar, em adequados níveis de confiabilidade e incerteza de medição, para a etapa de identificação de oportunidades de negócio.

O presente trabalho descreve a aplicação de uma metodologia que utiliza visão computacional e técnicas de aprendizado de máquina (*machine learning*) para obter uma estimativa da irradiância global. O treinamento e a calibração preliminares dos modelos foram realizados por meio de imagens do céu sincronizadas com medições oriundas de piranômetro. Na seção 2, é apresentada uma breve revisão sobre inteligência artificial, abordando as capacidades de aprendizado de máquina e visão computacional. Na seção 3, é descrita a metodologia utilizada no trabalho, com detalhamento das etapas envolvidas para treinamento e aplicação de redes neurais na estimativa de irradiância solar. Os resultados e as discussões são apresentados na seção 4, e as conclusões na seção 5.

2 INTELIGÊNCIA ARTIFICIAL

A estimativa da geração pode ser uma ferramenta aliada para possibilitar o aumento da penetração das energias renováveis intermitentes no sistema elétrico. No caso da geração fotovoltaica, o recurso solar está intimamente relacionado à produção de energia de um determinado sistema. Nesse sentido, vários trabalhos vêm sendo desenvolvidos com foco em estimar a irradiância solar, utilizando principalmente sistemas de Inteligência Artificial (IA).

Segundo Joshi (2017), IA é um modo de fazer com que máquinas pensem e se comportem com inteligência, tentando imitar o sistema de aprendizagem, truques, pensamento e ações dos seres humanos. Para um sistema ser considerado inteligente, ele precisar conter algumas habilidades, entre elas a Aprendizagem de Máquina (AM) e a Visão Computacional (VC), as quais foram utilizadas neste trabalho.

A VC remete à capacidade de um sistema, através de imagens, perceber objetos, formas, padrões, estruturas tridimensionais do mundo real. Já a AM está relacionada à capacidade de se adaptar a novas circunstâncias, detectá-las e relacioná-las a padrões, ou seja, uma detecção automatizada de padrões em um conjunto de dados (Russell & Norvig, 2016), (Szeliski, 2010), (Shalev-Shwartz & Ben-David, 2014).

A utilização de imagens digitais foi introduzida por volta de 1920, e, com o avanço da capacidade de processamento dos sistemas atuais e a expansão da VC, as imagens digitais e seus respectivos processamentos têm diversas aplicações, desde câmera de celulares até a medicina (Gonzalez & Woods, 2011).

Segundo Gonzalez e Woods (2011), uma imagem pode ser definida como uma função de duas dimensões, $f(x, y)$, onde x e y são coordenadas de um plano e $f(x, y)$ é a intensidade da imagem nos pontos x e y. Assim, o processamento digital de imagem consiste em identificar, analisar e processar cada ponto $f(x, y)$ da imagem, chamado de *pixel*, utilizando um sistema digital.

Um dos métodos utilizados como base para o processamento digital e extração de características de imagens é o histograma de imagem, que consiste em um gráfico que representa a frequência de ocorrência de diferentes intensidades de cores da imagem, com o intuito de extrair características da mesma. É possível utilizar um histograma RGB da imagem, cujo método consiste em adquirir três histogramas, um para cada canal de cor (vermelha, verde e azul), pois a cor é um descritor que simplifica a identificação e extração de objetos (Gonzalez & Woods, 2011), (Nixon, 2013), (Coste, 2019), (VeprIT, 2019).

O histograma da imagem tem várias aplicações, podendo ser utilizado, por exemplo, para aprimorar contraste e cores (Veluchamy & Subramani, 2019), segmentação de imagem (Rajinikanth & Couceiro, 2015), avaliação da estabilidade de combustíveis fósseis (Vráblík, Hidalgo-Herrador, & Černý, 2018), ou ainda, em reconhecimento de teclas na autenticação de usuários (Alpar, 2014).

A partir da extração de características, métodos de regressão podem ser utilizados para realizar estimação ou predição da informação que se deseja. Um dos métodos com grande evidência atualmente é a utilização de Redes Neurais Artificiais (RNA), que são modelos computacionais inspirados no sistema nervoso dos seres humanos. Uma RNA é composta por um ou mais neurônios artificias, interligados entre si através de conexões sinápticas, cujo intuito é simular o sistema nervoso dos seres humanos (Silva, Spatti, Flauzino, Liboni, & dos Reis Alves, 2016).

De acordo com Silva *et al.* (2016), as principais características de uma RNA são a adaptação por experiência, capacidade de aprendizado, capacidade de generalização, agrupamento de dados, tolerância a erros, armazenamento distribuído e facilidade de prototipação. Por essas várias características, as RNAs são utilizadas em diversos segmentos, distribuídos, desde processos de previsão, reconhecimento de padrões até classificação, como mostram Abiodun *et al.* (2018). Entre os segmentos de aplicação, podem-se elencar segurança, medicina, finanças, energia, gerenciamento, entre muitos outros.

De face ao exposto, vários trabalhos utilizam-se dos métodos descritos anteriormente para realizar a estimativa da disponibilidade da irradiância solar. Dentre eles, pode-se apresentar o trabalho de Kawakami *et al.* (2018), que faz a predição da irradiância global a partir de imagens RGB do céu e Rede Neural Profunda (RNP). Na mesma linha, Caldas e Alonso-Suárez (2019) propõem um método híbrido a partir da medida da irradiância em tempo real e imagens do céu para previsão de um a dez minutos da irradiância global.

Já no trabalho de Herrera-Carrillo *et al.* (2018), dois tipos de câmeras para aquisição de imagens do céu são comparados e, com as imagens é realizada uma regressão linear para a estimativa da irradiância global. Outro trabalho, propõe um sistema de rastreamento de nuvens através de entradas de vídeo do céu, para realizar a previsão da obstrução do Sol e da redução de irradiância global (Chang, Yao, Li, Tong, & Tu, 2017).

Por fim, Kamadinata *et al.* (2019) apresentam uma metodologia de previsão da irradiância global através de imagens do céu. Tal metodologia realiza a previsão de um a cinco minutos da irradiância a partir de cada imagem utilizando RNA.

Diante do exposto, os trabalhos apresentados anteriormente se limitam à obtenção da irradiância global, porém, como evidenciam Chang *et al.* (2017), a obstrução do Sol pelas nuvens é um dos maiores contribuidores da flutuação da irradiância solar. Assim, este trabalho propõe uma metodologia para avaliação da irradiância solar a partir do processamento de imagens do céu, usando como base o conceito de VC e AM através de RNAs.

3 METODOLOGIA

A fim de avaliar o nível de incidência local de irradiância solar a partir de uma imagem adquirida do céu, fez-se uso de uma técnica baseada em aprendizado de máquina, utilizando linguagem Python 3.7 e a biblioteca Caffe. De modo

geral, a aplicação desse tipo de técnica envolve a realização de uma sequência típica de etapas, as quais podem ser observadas no fluxograma apresentado na figura 1.

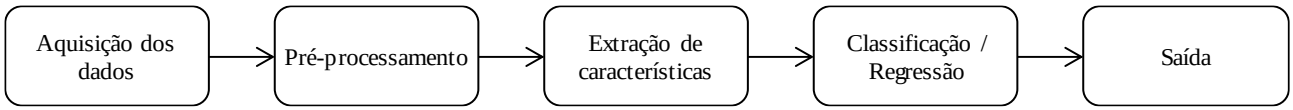

Figura 1 – Diagrama para aplicação da aprendizagem de máquina.

Primeiramente, na etapa de aquisição dos dados, foram capturadas imagens do céu a cada 30 segundos, com um sensor fotográfico (modelo OV5647) acoplado a uma lente do tipo olho de peixe (*fisheye*). Paralelamente, foram aquisitados os valores de irradiância global (uma amostra por segundo com média a cada 30 segundos), obtida por meio de um piranômetro (LI-200R), montado em um dispositivo mecânico apresentado na figura 2. A título de informação, esse aparato possui anel de sombreamento que permite a obtenção da irradiância difusa, que não foi utilizada nessa etapa do trabalho. Nesse momento, o objetivo foi verificar a viabilidade do emprego da metodologia para obtenção dos resultados almejados. Esses dados foram empregados para treinamento e teste do sistema de estimativa, de modo que foram selecionadas 67.803 imagens entre os dias 15/09/2018 a 17/10/2018, na cidade de Curitiba/PR. Nas próximas etapas desse projeto de pesquisa, serão utilizados piranômetros padrão secundário com rastreamento, para formação de base de dados com período maior e oriundo de diversas localidades.

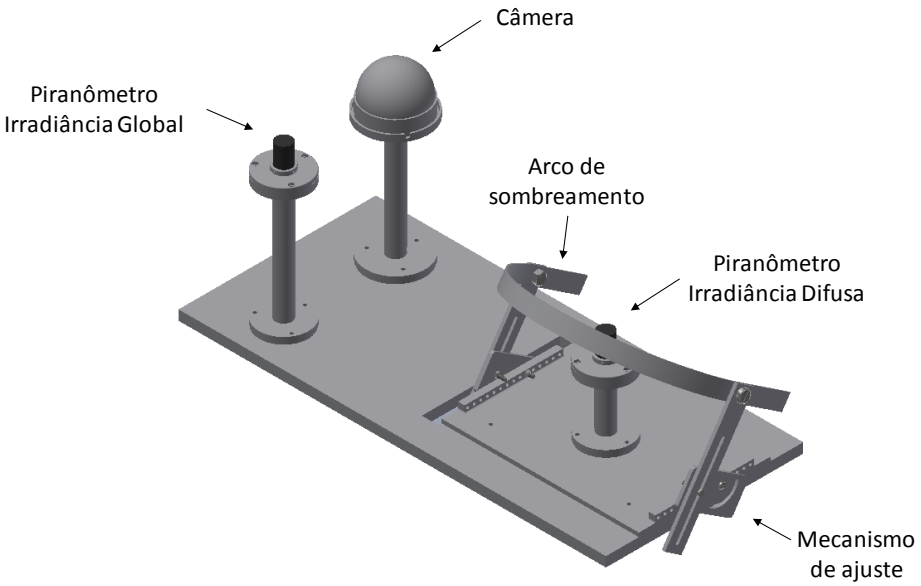

Figura 2 – Dispositivo de medição da irradiância difusa.

Em seguida, durante a etapa de pré-processamento, as imagens foram manipuladas com intuito de aumentar qualidade da informação por meio da alteração conveniente de suas propriedades (contraste, nitidez, cor, dentre outras). Nessa etapa, também foi realizada a adequação da imagem para os formatos e modelos exigidos pelos algoritmos implementados, com a redução da resolução original das imagens para a resolução padrão 800 x 600 *pixels*.

Depois, na etapa de extração de características, realizou-se o cálculo dos histogramas RGB (componentes *Red*, *Green* e *Blue*) da imagem e, a partir dos três histogramas, obteve-se um vetor com 768 características, o qual foi utilizado para o treinamento da rede neural para determinação das intensidades de irradiância solar. É importante salientar que os preditores (dados de entrada da rede neural) foram compostos pelo diagrama RGB normalizado das imagens, compondo 768 dados de entrada.

Por fim, a última etapa consistiu no treinamento do sistema de predição, através de redes neurais, comparando RNA com RNP. Aqui vale ressaltar que a RNA foi formada por apenas uma camada escondida contendo 110 neurônios. Já para a RNP, foram utilizadas 6 camadas escondidas, com 110 neurônios cada. Para ambas as topologias de redes testadas, todas as funções de ativação utilizadas são do tipo linear retificada, (ReLU, do inglês *Rectified Linear Unit*). Para treinar as redes, foram utilizadas 67.803 imagens do céu, das quais 65.059 foram utilizadas como conjunto para treinamento e 2.744 para conjunto de teste, juntamente com os respectivos valores de irradiância.

Vale destacar que, até o presente momento, todo o sistema foi treinado para a obtenção da irradiância global horizontal. Em etapas posteriores, será buscada a implementação conjunta das imagens e irradiâncias global e difusa horizontais, com informações oriundas dos sensores de umidade e temperatura, a fim de se avaliar possíveis correlações que possam melhorar o acerto do modelo de regressão. Os resultados preliminares para a estimativa da irradiância global estão dispostos na seção 4.

4 RESULTADOS E DISCUSSÕES

A primeira etapa de avaliação do modelo consistiu em treinar a rede e depois testá-la, utilizando os dados do dia 17/09/2018, excluindo esses dados do banco de treinamento. Os resultados obtidos na etapa de teste podem ser observados na tabela 1, e nas figuras 3 e 4. As métricas utilizadas para comparação dos resultados, erro médio absoluto (MAE) e Raiz do Erro Quadrático Médio ($REQM$), são calculadas conforme as expressões (1) e (2) respectivamente.

$$EMA = \sum_{k=1}^{n} \left| G_{HOR,Estimada,k} - G_{HOR,Medida,k} \right| \tag{1}$$

$$REQM = \sqrt{\frac{1}{n} \sum_{k=1}^{n} \left(G_{HOR,Estimada,k} - G_{HOR,Medida,k} \right)^2} \tag{2}$$

Tabela 1 – Comparação dos resultados para os dados de teste do dia 17/09/2018.

Modelo de Regressão	Erro Médio Absoluto $[W/m^2]$	Raiz do Erro Quadrático Médio $[W/m^2]$
RNA	5,35	9,14
RNP	6,27	9,88

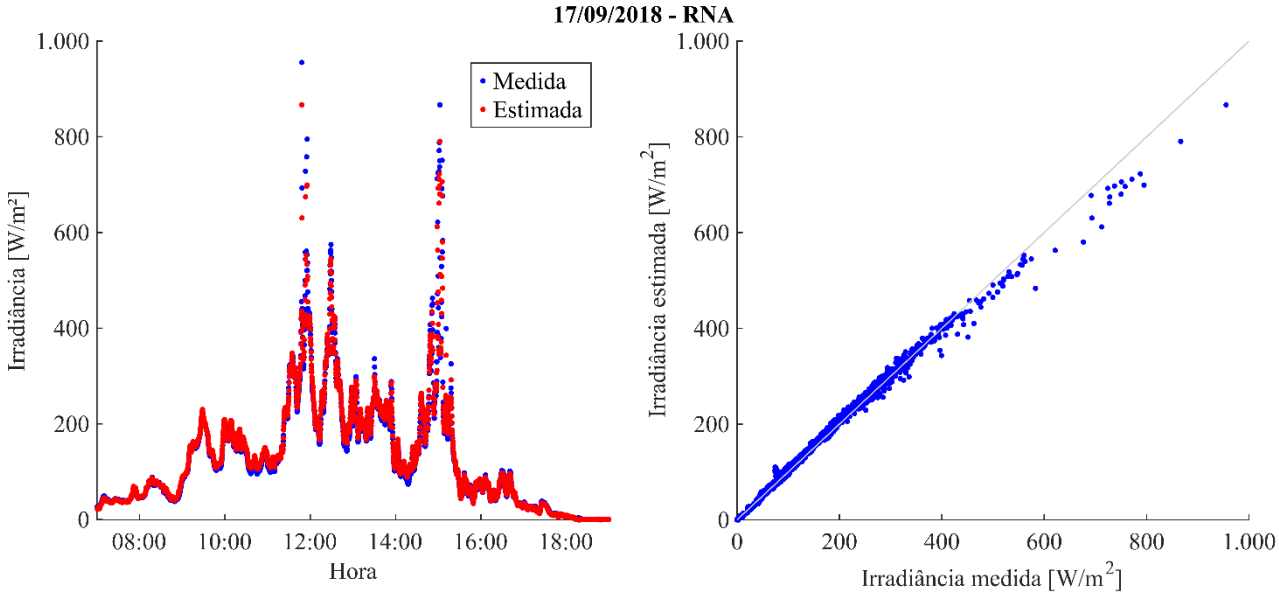

Figura 3 – Irradiância global e erro de estimativa para o dia 17/09/2018 utilizando uma RNA.

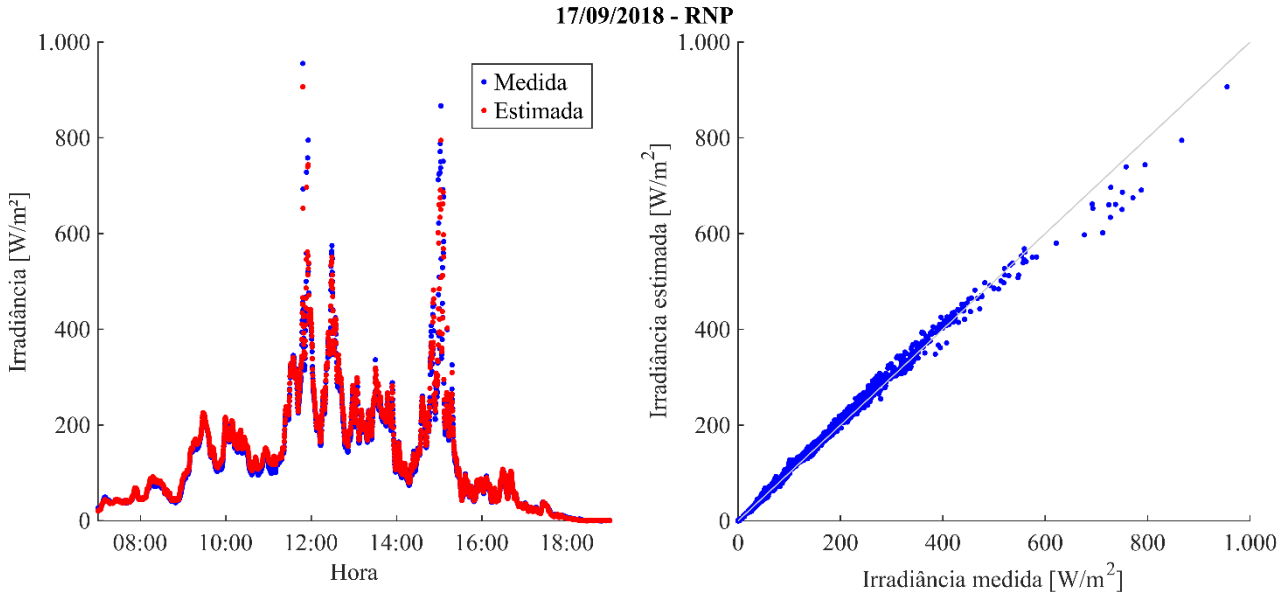

Figura 4 – Irradiância global e erro de estimativa para o dia 17/09/2018 utilizando uma RNP.

Já a segunda etapa de avaliação do modelo consistiu em treinar a rede e depois testá-la utilizando os dados do dia 07/10/2018, excluindo esses dados do banco de treinamento. Os resultados obtidos na etapa podem ser visualizados na tabela 2 e nas figuras 5 e 6.

Tabela 2 – Comparação dos resultados para os dados de teste do dia 07/10/2018.

Modelo de Regressão	Erro Médio Absoluto $[W/m^2]$	Raiz do Erro Quadrático Médio $[W/m^2]$
RNA	8,25	14,43
RNP	6,82	14,86

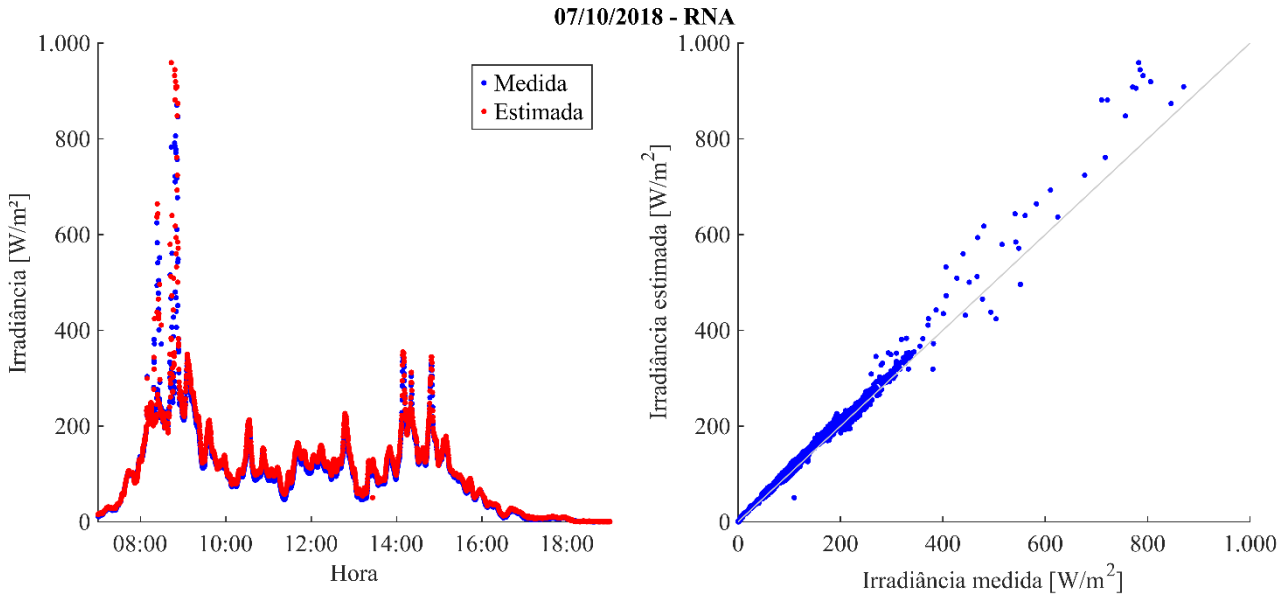

Figura 5 – Irradiância global e erro de estimativa para o dia 07/10/2018 utilizando uma RNA.

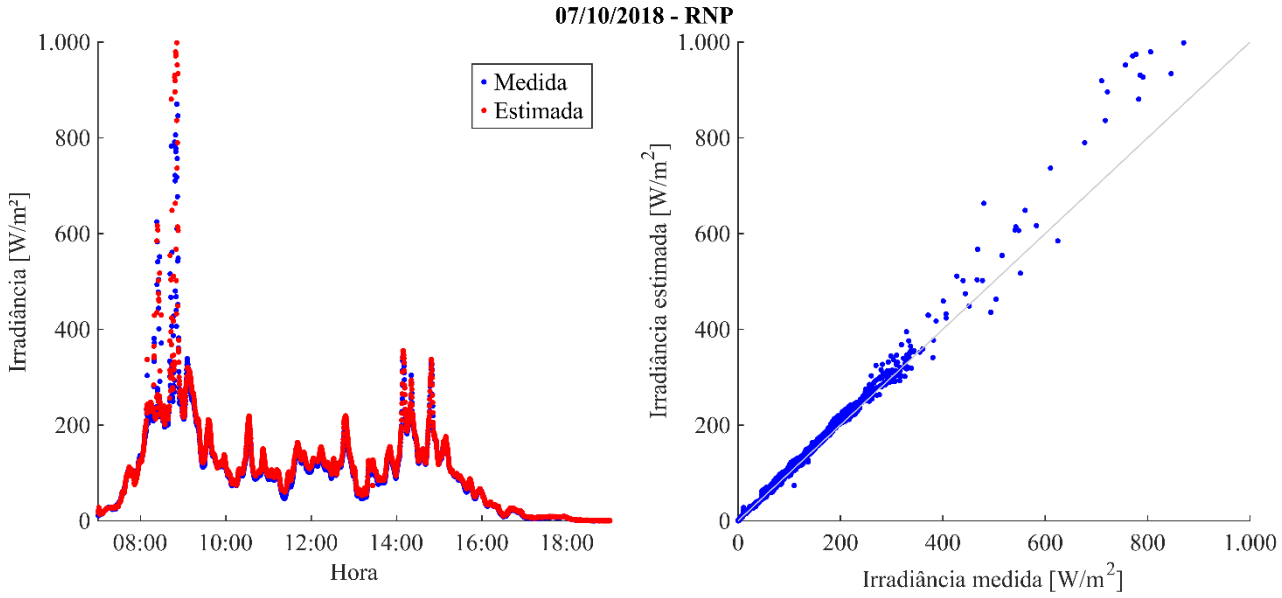

Figura 6 – Irradiância global e erro de estimativa para o dia 07/10/2018 utilizando uma RNP.

Em ambos os testes realizados, observa-se que os modelos testados realizaram a estimativa da irradiância com baixo erro médio absoluto, variando de 5,35 W/m² a 8,25 W/m², apresentando-se como uma alternativa para a estimativa da irradiância global. Contudo, não se verificaram ganhos significativos de precisão de estimativa da irradiância global utilizando-se uma RNP, através da análise do erro médio absoluto.

Também é possível constatar, com auxílio dos gráficos apresentados e dos valores dos erros quadráticos médios, que apesar do pequeno erro na determinação de baixos valores de irradiância, o erro associado se apresentou maior na determinação de altos valores de irradiância, associado às rápidas passagens de nuvens em dias nublados. Vale salientar que a maior parte dos dados do período analisado é referente a dias nublados.

Os resultados se mostraram promissores em relação à viabilidade do método para a estimativa da irradiância global e, dessa forma, através de alguns ajustes na topologia das redes utilizadas (tais como números de camadas, quantidades de neurônios, entre outras configurações), a próxima etapa será implementar um modelo capaz de realizar a separação da componente difusa e o cálculo da componente direta. Uma vez que as redes neurais estejam treinadas para diversas condições de céu, a expectativa é de que a capacidade de generalização do modelo permita o uso em todo o território nacional, dispensando o conhecimento prévio da irradiância solar local.

5 CONCLUSÕES

Devido ao fato que poucos dados foram coletados, criou-se um pequeno banco de dados de treinamento, o que pode não ter sido suficiente para que o sistema de estimativa alcançasse a generalização das situações impostas. Além da pequena quantidade de dados, a maior partes desses foram coletados sob céu encoberto por nuvens. Esse fato pode ter sido um fator determinante no aprendizado do sistema de estimativa, pois a generalização do sistema foi realizada para situações que apresentaram céu nublado ou parcialmente nublado, mas não para situações de céu limpo, gerando maiores desvios na estimativa de maiores valores de irradiância.

Mesmo assim, a partir dos resultados obtidos, verificou-se que o método avaliado se mostrou promissor como ferramenta para a estimativa dos níveis de irradiância solar global. Em etapas futuras e após os devidos ajustes, será feita a extensão do modelo para a obtenção das componentes da irradiância difusa e direta. Dessa forma, uma vez treinadas e implementadas as redes neurais, o uso de ferramentas de VC e IA se mostraram como uma alternativa de baixo custo para o levantamento do recurso solar, já que a solução dispensa o uso de anel de sombreamento ou pireliômetro com rastreador solar.

Além disso, constatou-se que o cálculo por histogramas RGB teve custo computacional inferior a outros métodos de extração de características, e que a redução da resolução (e, portanto, do tamanho da imagem) proporcionou ganho computacional, além de reduzir a demanda por memória de armazenamento, trazendo particular vantagem na sua implementação em sistemas embarcados.

Por fim, observou-se que redes neurais são mais estáveis que outros métodos de estimativa quando utilizada para avaliar a radiação de dias com características diferentes, não apresentando ganhos significativos de precisão na determinação da intensidade da irradiância global, comparativamente aos modelos de redes neurais artificiais e redes neurais profundas.

REFERÊNCIAS

Abiodun, O., Jantan, A., Omolara, A., Dada, K., Mohamed, N., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. Heliyon, 4(11), e00938.

Agência Nacional de Energia Elétrica (ANEEL). (2020a). Banco de Informações de Geração (BIG) - Capacidade de geração do Brasil. Disponível em <http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/GeracaoTipoFase.asp>. Acesso em fevereiro de 2020.

Agência Nacional de Energia Elétrica (ANEEL). (2020b). *Unidades consumidoras com geração distribuída*. Disponível em <https://www.aneel.gov.br/outorgas/geracao/-/asset_publisher/mJhnKIi7qcJG/content/registro-de-central-geradora-de-capacidade-reduzida/655808?inheritRedirect=false&redirect=http%3A%2F%2Fwww.aneel.gov.br%2Foutorgas%2Fgeracao%3Fp_p_id%3D101_INSTANCE_mJhnKIi7q>. Acesso em fevereiro de 2020.

Alpar, O. (2014). Keystroke recognition in user authentication using ANN based RGB histogram technique. *Engineering Applications of Artificial Intelligence, 32*, 213 - 217.

Bloomberg New Energy Finance (BNEF). *Energy, vehicles sustainability - 10 predictions for 2020*. Disponível em <https://about.bnef.com/blog/energy-vehicles-sustainability-10-predictions-for-2020/>. Acesso em fevereiro de 2020.

Caldas, M., & Alonso-Suárez, R. (2019). Very short-term solar irradiance forecast using all-sky imaging and real-time irradiance measurements. *Renewable Energy, 143*, 1643 - 1658.

Chang, M., Yao, Y., Li, G., Tong, Y., & Tu, P. (2017). Cloud tracking for solar irradiance prediction. *2017 IEEE International Conference on Image Processing (ICIP)*, (pp. 4387-4391).

Coste, A. (2019). *Histograms*. Disponível em <http://www.sci.utah.edu/~acoste/uou/Image/project1/Arthur_COSTE_Project_1_report.html>. Acesso em outubro de 2019.

Gonzalez, R., & Woods, R. (2011). *Digital Image Processing.* Pearson Education.

Herrera-Carrillo, N., Rivero, M., Gómez-Ramírez, E., & Loera-Palomo, R. (2018). Solar irradiance estimation based on image analysis. *2018 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*, (pp. 1-6).

Joshi, P. (2017). *Artificial Intelligence with Python.* Packt Publishing.

Kamadinata, J., Ken, T., & Suwa, T. (2019). Sky image-based solar irradiance prediction methodologies using artificial neural networks. *Renewable Energy, 134*, 837 - 845.

Kawakami, K., Takahashi, A., Imai, J., & Funabiki, S. (2018). Measuring Method for Solar Irradiance at Multi-points with Different Color Based on Image Analysis. *2018 IEEE Energy Conversion Congress and Exposition (ECCE)*, (pp. 2543-2548).

Nixon, M. (2013). *Feature Extraction and Image Processing.* Elsevier Science.

Rajinikanth, V., & Couceiro, M. (2015). RGB Histogram Based Color Image Segmentation Using Firefly Algorithm. *Procedia Computer Science, 46*, 1449 - 1457.

Renewable Energy Policy Network for the 21st Century (REN21). *Renewables 2019. Global status report*. Disponível em: <https://www.ren21.net/wp-content/uploads/2019/05/gsr_2019_full_report_en.pdf> . Acesso em outubro de 2019.

Russell, S., & Norvig, P. (2016). *Artificial Intelligence: A Modern Approach.* Pearson.

Shalev-Shwartz, S., & Ben-David, S. (2014). *Understanding Machine Learning: From Theory to Algorithms.* Cambridge University Press.

Silva, I. N., Spatti, D. H., Flauzino, R. A., Liboni, L. H., & dos Reis Alves, S. F. (2016). *Artificial Neural Networks: A Practical Course.* Springer International Publishing.

Szeliski, R. (2010). *Computer Vision: Algorithms and Applications.* Springer London.

Veluchamy, M., & Subramani, B. (2019). Image contrast and color enhancement using adaptive gamma correction and histogram equalization. *Optik, 183*, 329 - 337.

VeprIT. (2019). *What is image histogram (using histogram)*. Disponível em <https://veprit.com/photography-guide/using-histogram/what-is-image-histogram> . Acesso em outubro de 2019.

Vráblík, A., Hidalgo-Herrador, J., & Černý, R. (2018). RGB histograms as a reliable tool for the evaluation of fuel oils stability. *Fuel, 216*, 16 - 22.

ESTIMATE OF LOCAL SOLAR IRRADIANCE USING ARTIFICIAL INTELLIGENCE

Abstract. *Estimating the annual energy production of a solar energy enterprise, regardless of its size, is a fundamental step for feasibility analyzes. Thus, the generation estimate can be an allied tool that can allow a greater penetration of renewable energies in the electrical system. In this context, recently, several studies have been developed with the objective of contributing to the estimates of the availability of solar irradiance using Artificial Intelligence (AI) systems. This work shows the first steps of development of a methodology that uses computer vision combined with computational intelligence, in order to evaluate the availability of solar irradiance of places of interest, based on the analysis of acquired*

images of the sky and a methodology based on machine learning. In this work, models were tested to determine the global irradiance in order to make a prior assessment of their performance. The obtained results suggest that the methodology is promising for application in the estimation of the levels of global solar irradiance and may be extended to the calculation of its diffuse and direct components, without the need to use a pyrheliometer and solar tracker or shading ring. Thus, it is intended to provide a low-cost alternative for preliminary estimates of the solar resource.

***Key words**: Solar Energy, Artificial Intelligence, Computer Vision*