



Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Previsão e otimização da geração de energia fotovoltaica em Rio Largo-AL

Leandro Vinícius Gomes da Silva¹, Ricardo Araujo Ferreira Junior², Igor Cavalcante Torres³, Marcos Alex dos Santos⁴, Cícero Manoel dos Santos⁵

¹ Graduado em Engenharia de Energia, Campus de Engenharias e Ciências Agrárias, Universidade Federal de Alagoas, BR-104, km 85, s/n, CEP 57100-000, Rio Largo, Alagoas. (82) 3214-1317. leandrovinicius97@outlook.com. ² Dr. em Agronomia, Professor Adjunto, Campus de Engenharias e Ciências Agrárias (CECA), Universidade Federal de Alagoas (UFAL), BR-104, km 85, s/n, CEP 57100-000, Rio Largo, Alagoas. (82) 3214-1317. ricardo.junior@ceca.ufal.br (autor correspondente). ³ Dr. em Tecnologias Energéticas Nucleares, Professor Adjunto, CECA, UFAL, BR-104, km 85, s/n, CEP 57100-000, Rio Largo, Alagoas. (82) 3214-1317. igor.torres@ceca.ufal.br. ⁴ Dr. em Ciências (Engenharia de Sistemas Agrícolas), Professor Adjunto, CECA, UFAL, BR-104, km 85, s/n, CEP 57100-000, Rio Largo, Alagoas. (82) 3214-1317. marcos.santos@ceca.ufal.br. ⁵ Dr. em Agronomia, Professor Adjunto II, Faculdade de Engenharia Agrônômica, Universidade Federal do Pará, Campus Altamira, Brasil. cmanoel@ufpa.br.

Artigo recebido em 11/07/2023 e aceito em 14/02/2024

RESUMO

A previsão de produção de energia elétrica é fundamental para que o Operador Nacional do Sistema Elétrico (ONS) possa atender a demanda por energia elétrica sem restrições, principalmente quando a matriz elétrica é composta por recursos energéticos renováveis e intermitentes. O presente estudo visa prever a geração de energia de uma usina solar fotovoltaica e avaliar qual a configuração dos módulos fotovoltaicos que possibilita a máxima geração de energia no ano, concatenado com o horário de maior demanda do Sistema Interligado Nacional (SIN) no verão. Utilizando inteligência artificial previu-se a temperatura do ar que foi transformada em previsões de irradiação solar global. A máxima potência dos módulos fotovoltaicos e a eficiência de conversão dos inversores foram modeladas pela temperatura do ar e a irradiação solar, previstas juntamente de outros parâmetros característicos, obtidos no catálogo técnico de dados do fabricante. As previsões de temperatura do ar foram satisfatórias e puderam ser transformadas em previsões de irradiação e geração de energia elétrica com baixa propagação de erro. Contudo, em períodos de céu nublado as previsões obtiveram menor acurácia. A configuração ótima do arranjo fotovoltaico foi de inclinação de 13,21° e azimute de 126,92°.

Prediction and optimization of photovoltaic energy generation in Rio Largo-AL

ABSTRACT

The forecast of electric energy production is essential for the National Electric System Operator to meet the demand for electric energy without restrictions, mainly in an electrical matrix composed of renewable and intermittent energy resources. This study aims to predict the energy generation of a photovoltaic solar plant and to evaluate which photovoltaic modules configuration allows for the maximum energy generation in a year and at the time of greatest demand of the SIN in the summer. The air temperature was predicted by using artificial intelligence, which was used to estimate solar radiation by a well-known model. The maximum power of the photovoltaic modules and the conversion efficiency of the inverters were modeled according to the predictions of temperature and solar radiation, along with other characteristic parameters obtained from manufacturer's data sheet. The temperature changes were satisfactory and could be transformed into changes in irradiation and generation of electrical energy without major error propagation, however in periods of cloudy sky as changes obtained less accuracy. The best configuration of the photovoltaic modules was a large expansion of 13.21 ° and azimuth of 126.92 °.

Introdução

O Brasil está entre os países com matriz energética mais limpa do mundo. E, quando se trata de fontes de energia apenas para geração de eletricidade, o país tem um destaque ainda melhor em relação à média global. No ano de 2022, conforme Balanço Energético Nacional 2023, 92,1% da eletricidade do país foi proveniente de

fontes renováveis (EPE, 2023). Essa alta porcentagem de renováveis é pela participação expressiva de fonte hidráulica (cerca de 62% da matriz elétrica em 2022) na geração de eletricidade no país. Todavia, a diversificação de fontes de energia é importante tanto para atender a demanda energética, quanto para uma segurança elétrica,

principalmente em anos de crise hídrica. Essas fontes alternativas necessitam ser limpas e renováveis para o país alcançar a meta de redução de emissões de gases de efeito estufa (GEE) e contribuir com a atenuação das mudanças climáticas.

A geração de eletricidade fotovoltaica (FV) é uma das alternativas na mitigação de emissões de GEE. O aumento da eficiência de conversão das placas (média mundial 15%) e a diminuição do custo de instalação, US\$ 4,7/Wp em 2021 para US\$ 0,88/Wp em 2020 (Silva et al., 2023) permitiram uma rápida adesão dessa fonte ao setor elétrico. Com o grande potencial que todas as regiões do Brasil têm em gerar elevadas quantidades de energia elétrica por meio da tecnologia FV, o Plano Decenal de Energia, desenvolvido pela Empresa de Pesquisa Energética (EPE), espera-se que aumente o uso da tecnologia FV ainda mais nos próximos anos (Iglesias e Vilaça, 2022).

Os picos de consumo de energia elétrica no Brasil, historicamente, foram observados após as 17 horas (horário de Brasília), decorrente do fim do período de luz natural e o retorno de uma grande parcela da população às casas. Todavia, em função das mudanças no padrão de consumo de energia elétrica nos últimos anos, o Operador Nacional do Sistema Elétrico (ONS) tem registrado picos de demanda em torno das 15 horas, sobretudo nos meses mais quentes (verão). Essa alta demanda de carga no período da tarde é influenciada, principalmente, porque no Brasil a refrigeração ambiental, em maioria, é por meio de equipamentos de ar-condicionado (EPE, 2018). O estudo de 2018 da EPE ressalta que algumas das regiões mais quentes do país são também as regiões mais pobres, fato que indica a existência de uma demanda ainda reprimida por refrigeração ambiental.

Diante deste cenário, cabe evidenciar a relevância dos geradores solar fotovoltaicos (FV), pois operam em certa sincronia com o novo perfil da curva de carga do sistema elétrico brasileiro. A potência instalada da energia solar fotovoltaica alcançou a marca de 37.293 MW no Brasil, a segunda fonte de energia com maior potência instalada, com 16,50% de participação na matriz elétrica brasileira, atrás apenas da energia hidráulica que conta com 48,80% (ABSOLAR, 2024). Nesse contexto, previsões de produção de energia elétrica por geradores solar FV são fundamentais não só para a operação e planejamento do Sistema Interligado Nacional (SIN), mas também para as concessionárias

distribuidoras de energia elétrica, operadores de usinas fotovoltaicas e agentes do mercado livre de energia. Através de modelagem de produção de uma usina FV, é possível avaliar quanto é a geração de eletricidade em função da configuração dos módulos no horário de maior demanda do SIN, informação importante para tomada de decisões.

O conhecimento da irradiância solar incidente em planos inclinados é o ponto chave para o sucesso de modelos de previsão estimativa de produção de energia elétrica por um gerador solar FV (Laudani, 2021). Todavia, dificilmente, sensores são instalados em planos inclinados. O fluxo de radiação solar incidente em um módulo FV depende da latitude, dia do ano, inclinação e ângulo azimutal do plano dos módulos, hora do dia e ângulo de radiação incidente (Božiková et al., 2021)

Na literatura existem diversas abordagens, com boa acurácia, para estimar a irradiação solar global incidente em um plano horizontal com base em diferentes variáveis meteorológicas de entrada (ex. temperatura do ar, umidade relativa do ar, velocidade do vento, precipitação), sendo a abordagem em função de dados de temperatura do ar (Hargreaves & Samani, 1982) umas das primeiras. Yohanna et al. (2011) usaram um modelo empírico para determinar a média mensal diária da irradiação solar global em uma superfície horizontal para a região de Makurdi, na Nigéria. Antonopoulos et al. (2019) utilizaram equações empíricas, como o método de Hargreaves, redes neurais artificiais (RNA) e métodos de regressão multilinear (MLR) para estimar a irradiação solar. Jahani e Mohammadi (2018) compararam diferentes tipos de modelos (RNA e modelos empíricos) para a estimativa da irradiação solar global diária no Irã e utilizaram duração do brilho solar e a temperatura do ar como variáveis de entrada. Em relação a estimativa em planos inclinados, Iqbal (1983) tem se destacado, sendo referência de vários estudos.

O objetivo deste trabalho foi desenvolver um modelo de previsão da produção de energia fotovoltaica com base em algoritmos genéticos (AG), redes neurais artificiais e modelagem empírica da temperatura do ar em paralelo com a irradiância solar global. Além disso, avaliar qual a inclinação e direção dos módulos fotovoltaicos que possibilitam a otimização geração de energia no horário de maior demanda do SIN no verão.

Material e métodos

Dados meteorológicos

As medidas de irradiância solar global no plano horizontal e temperatura do ar (T_a) foram obtidas da Estação Agrometeorológica Automática do Campus de Engenharia e Ciências Agrárias (CECA) da Universidade Federal de Alagoas (UFAL), localizada no município de Rio Largo, Alagoas (09°28'02" S; 35°49'43" W e 127 m) nos anos de 2016 a 2019 (Figura 1). No presente estudo, o local escolhido está inserido na região nordeste, potencialmente rica em irradiância solar (Pereira et al., 2017). O clima da região é megatérmico e úmido, com deficiência hídrica moderada no verão e considerável excesso de água no inverno. O local recebe 70% de sua precipitação anual total (1818 mm) durante os meses de abril a agosto. A temperatura do ar varia de 19,3 (agosto) a 31,7 °C (janeiro) com média anual de 25,4 °C e umidade média mensal do ar acima de 70% (Souza et al., 2004).



Figura 1. Localização da área onde foi realizada a pesquisa.

No ano de 2019 quatro piranômetros (Eppley modelo 8- 48, B&W) foram instalados em planos inclinados à 10° (valor aproximado da latitude local da pesquisa) em relação ao plano horizontal com direção para cada ponto cardinal (Leste, Oeste, Norte e Sul) e um sensor instalado na horizontal para o monitoramento da irradiância solar global (Figura 2). Todos os sensores foram calibrados com um sensor padrão de referência. Vale ressaltar que, geralmente, é recomendado que o sistema fotovoltaico seja instalado com um

ângulo de inclinação igual à latitude do local (Božiková et al., 2021) e direcionado para o hemisfério oposto, ou seja, a instalação de módulos FV fixos (sem rastreamento solar) no Hemisfério Sul é recomendada para a direção norte.

A temperatura do ar (T_a) foi monitorada por um termohigrômetro automático (HMP45C, Campbell Scientific, Logan, Utah) instalado a 2,0 m acima da superfície. As medidas foram realizadas em intervalos de 10 segundos, e suas médias armazenadas a cada 1 minuto, com auxílio de um datalogger (CR1000, Campbell Scientific Inc, USA).



Figura 2. Piranômetros (Eppley modelo 8- 48, B&W) instalados nos planos Leste, Oeste, Norte e Sul inclinados à 10° e no plano horizontal.

Previsão da temperatura do ar

A previsão da Temperatura do ar máxima (T_x) e mínima (T_n) diária e média mensal foi feita utilizando uma rede neural artificial (RNA) do tipo *Multilayer Perceptron (MLP) feedforward*, totalmente conectada e implementada no *software open-source Rstudio*. A arquitetura empregada para a RNA foi composta por uma camada de entrada, uma camada intermediária (oculta) e uma de saída, sendo estas duas últimas ativadas pela função sigmoideal.

A série temporal utilizada contém observações diárias de T_x e T_n dos anos de 2016 a 2019. O treinamento da RNA-MLP foi executado com as observações do período de 2016 a 2018 utilizando método de aprendizagem *backpropagation* com dez mil épocas e a validação foi feita utilizando o conjunto de dados de todo o ano de 2019.

A RNA-MLP foi otimizada mediante um algoritmo genético (AG). O AG inclui a codificação de soluções, o cálculo de ajustes e a

aplicação de operadores de multiplicação, cruzamento e mutação (Jang et al., 1997; Kaplan et al., 2022). A convergência do algoritmo é estabelecida pela condição do critério de parada, finalizando o algoritmo, dessa forma, a melhor solução entre as avaliadas é obtida, associando-a ao cromossomo. As soluções matemáticas (arquitetura e configuração da rede) são tratadas como cromossomos, representado por um vetor de onze dimensões, podendo cada uma ser preenchido pelos elementos {0, 1, 2, 3}. O número de entradas da RNA é determinado pela soma simples dos três primeiros elementos do vetor, o número de neurônios na camada oculta pela soma do quarto ao oitavo elemento e a taxa de aprendizagem é a soma dos três últimos elementos do vetor multiplicada por um décimo. Na Figura 3, observa-se o fluxo resumido de execuções do algoritmo genético.




Figura 3. Fluxo de execuções do algoritmo genético.

No AG, os cromossomos são submetidos aos operadores genéticos. Inicialmente são gerados dez cromossomos de forma randômica (GERA POPULAÇÃO INICIAL). A fase seguinte é avaliar a população inicial gerada (AVALIA POPULAÇÃO INICIAL), nessa fase cada RNA-

MLP representada por seu cromossomo respectivo cromossomo gerado é treinada (TREINA REDE NEURAL) e recebe uma nota sob o critério de que quanto menor for erro absoluto médio percentual na fase de treinamento da RNA MLP, maior será a nota de treinamento que este recebe (NOTA TREINAMENTO). Não atingido o critério de parada (executar por 30 gerações), inicia-se a fase dos operadores genéticos.

Os dois cromossomos da população são selecionados pelo método da roleta para efetuar cruzamentos (SELECIONA GENITORES). O material genético dos genitores é submetido ao crossover de ponto de corte único (CROSSOVER), gerando um novo cromossomo, sujeito a mutações a uma taxa de 5,00% por indivíduo (MUTAÇÃO), gerando desta forma um novo indivíduo. Novos indivíduos também podem ser gerados através do elitismo, que ocorre quando o mesmo indivíduo é selecionado duas vezes pelo método da roleta e não ocorre mutações no cromossomo gerado (ELITISMO). A fase dos operadores genéticos é repetida por dez vezes, gerando dez novos indivíduos, gerando uma nova população que substitui a população anterior. O AG é repetido trinta gerações (30 vezes, critério de parada), ao final das execuções seleciona-se o melhor indivíduo, ou seja, a melhor solução matemática dentre as avaliadas. O AG foi executado cinco vezes e foi escolhida a melhor solução. Executou-se dois tipos de previsões: previsão inicial; realizada sem conhecimento de quaisquer valores do conjunto de previsão; previsão atualizada; a previsão atual é realizada incluindo o valor anterior observado.

Previsão da irradiação solar global diária no plano horizontal (Hg)

As previsões de temperatura de ar foram usadas para a estimativa da irradiação solar global diária no plano horizontal (H_g , $\text{Wh m}^{-2} \text{dia}^{-1}$) através do modelo de Hargreaves & Samani (1982):

$$H_g = k \cdot H_0 (T_x - T_n)^{0,5} \quad (1)$$

em que, k é o coeficiente ajustado, igual a 0,16 (região interior) ou 0,19 (regiões costeiras), utilizado no presente estudo; T_x e T_n são a temperatura do ar ($^{\circ}\text{C}$) máxima e mínima, respectivamente; H_0 é a irradiação solar no topo da atmosfera ($\text{Wh m}^{-2} \text{dia}^{-1}$) (Iqbal, 1983):

$$H_0 = \frac{24}{\pi} I_{sc} E_0 [(\pi/180)\omega_s(\sin \delta \sin \phi) + (\cos \delta \cos \phi \sin \omega_s)] \quad (2)$$

em que, I_{sc} é a constante solar (1.367 W m^{-2}); E_0 é o fator de correção da excentricidade da Terra; ω_s é o ângulo horário; δ é a declinação solar; ϕ é a latitude local (Iqbal, 1983):

$$E_0 = 1 + 0,033 \cos[(2\pi d_n/365)] \quad (3)$$

$$\omega_s = \cos^{-1}(-\tan \phi \tan \delta) \quad (4)$$

$$\delta = 23,45 \sin \left[\frac{360}{365} (d_n + 284) \right] \quad (5)$$

em que, d_n é o enésimo dia do ano.

A H_g prevista foi distribuída ao longo do fotoperíodo para obter a irradiação solar global horária (H_g^h) (Iqbal, 1983):

$$H_g^h = H_g \frac{\pi}{24} \frac{(24/\pi) \cdot \sin(\pi/24) \cdot \cos(\omega_i) - \cos(\omega_{ss})}{\sin(\omega_{ss}) - (\pi/180) \cdot \omega_{ss} \cdot \cos(\omega_{ss})} \quad (6)$$

em que, ω_i é o ângulo horário; ω_{ss} é o ângulo horário do pôr-do-sol para uma superfície horizontal.

Irradiação solar global superfície inclinada e orientada arbitrariamente

A determinação da irradiação solar global horária em uma superfície inclinada e orientada arbitrariamente ($H_g \beta \gamma^h$) foi feita a partir da H_g^h , conforme o *circumsolar model* (Iqbal, 1983), todavia foram utilizados os valores de H_g^h prevista (Eq. 6) e os valores de H_g^h observados por piranômetros na estação meteorológica, conforme anteriormente descrito e visualizado na Figura 2:

$$H_g \beta \gamma^h = H_g^h \frac{\cos(\theta_{\bar{h}})}{\cos(\theta_{z\bar{h}})} \quad (7)$$

em que: $\theta_{\bar{h}}$, e $\theta_{z\bar{h}}$ são, respectivamente, o ângulo de incidência para uma superfície arbitrariamente orientada no meio de uma hora e o ângulo zenital no meio de uma hora (Iqbal, 1983):

$$\cos \theta_{\bar{h}} = (\sin \phi \cos \beta - \cos \phi \sin \beta \cos \gamma) \sin \delta + (\cos \phi \cos \beta + \sin \phi \sin \beta \cos \gamma) \cos \delta \cos \omega + \cos \delta \sin \beta \sin \gamma \sin \omega \quad (8)$$

$$\cos \theta_{z\bar{h}} = \sin \delta \sin \phi + \cos \delta \cos \phi \cos \omega \quad (9)$$

em que, β é a inclinação do plano do módulo em relação ao plano horizontal e γ é o azimute do

plano. O azimute é o ângulo entre a direção dos módulos fotovoltaicos em relação à direção norte ou sul, no presente estudo foi definido em relação ao sul (exemplo: $\gamma = -90^\circ$ é leste, $\gamma = 0^\circ$ é sul e $\gamma = +90^\circ$ é oeste).

Previsão e estimativa de energia elétrica gerada

A determinação da geração de energia seguiu a metodologia de Frontin et al. (2017), na qual duas fontes de dados de temperatura do ar e irradiação solar global foram utilizadas: 1) dados observados (chamado de geração de energia estimada); e 2) dados previstos com a metodologia supracitada (chamado de geração de energia prevista).

$$E_g = \int_{\omega_{sr}}^{\omega_{ss}} P_{\max} \cdot \frac{H_g \beta \gamma^h}{I_{ref}} \cdot [1 - \lambda \cdot (T_{célula} - T_{c,ref})] \cdot \eta_{cc-ca} \cdot \eta_{cabos} d\omega \quad (10)$$

em que E_g é a energia produzida pelo gerador FV (Wh); $H_g \beta \gamma^h$ é irradiação solar global horária em uma superfície orientada arbitrariamente; I_{ref} é a irradiância solar de referência, (W m^{-2}); $T_{c,ref}$ é a temperatura da célula fotovoltaica em condições padrão de teste (STC) ($^\circ\text{C}$); η_{cc-ca} é a eficiência de conversão CC-CA do inversor (98,6 %); η_{cabos} é o fator de perdas nos cabos (0,96); λ é o coeficiente que relaciona a variação da potência no ponto de máxima potência com a temperatura; $P_{\max}$ é a potência máxima definida de um painel fotovoltaico sob as condições padrão de teste (STC) industrial de $I_{ref} = 1.000 \text{ W m}^{-2}$ com ângulo zero de incidência, espectro solar de massa de ar a 1,5 e $T_{c,ref}$ de 25°C ; e $T_{célula}$ é a temperatura de operação das células fotovoltaicas ($^\circ\text{C}$), obtida por

$$T_{célula} = T_a + \frac{H_g \beta \gamma^h}{800} (NOCT - 20) \quad (11)$$

em que: T_a é a temperatura do ar (ou temperatura ambiente); NOCT é temperatura nominal de operação da célula fotovoltaica; 800 e 20 são, respectivamente, a irradiância em W m^{-2} e a temperatura em $^\circ\text{C}$ que o módulo fotovoltaico é submetido em laboratório para medir a NOCT.

Indicadores estatísticos

A avaliação dos erros das previsões de temperatura do ar e irradiação solar nas estimativas de geração de energia baseou-se nos seguintes indicadores estatísticos: Erro Absoluto Médio (EAM) e Raiz do Erro Quadrático Médio (RMSE).

Avaliação da direção e inclinação dos módulos fotovoltaicos na geração de energia

A avaliação da configuração (direção e inclinação dos módulos fotovoltaicos) que possibilita a otimização da geração de energia média anual e na hora de maior demanda média anual do SIN, para o ano de 2019, que está compreendida no fotoperíodo da região de estudo:

$$nota = \bar{e}_{anual} + \bar{e}_{hpico} \quad (12)$$

em que: $\bar{e}_{anual}$ é a energia média anual diária gerada e $\bar{e}_{hpico}$ é a energia média anual gerada no horário de máxima demanda durante o fotoperíodo (15:00 – 15:59).

Em virtude da ausência de um gerador solar real, será considerado que a geração do sistema é dada pela estimativa de geração de um gerador solar FV fictício composto por dezesseis módulos de silício policristalino modelo CS6U-315P da marca Canadian e um inversor da marca ABB modelo UNO-DM-5.0-TL-PLUS, portanto um sistema de 5,04 kWp.

Resultados e discussão

Previsão da temperatura do ar

As RNA fornecidas pelo algoritmo genético que produziram os melhores resultados, na fase de treinamento para as previsões de temperatura do ar estão listadas na Tabela 1. Representadas pelo código (MLP – número de entradas – número de neurônios na camada intermediária – taxa de aprendizagem).

Os resultados para as previsões da temperatura no ano de 2019 são observados na Tabela 2. Espera-se que as previsões iniciais, por serem feitas com valores também previstos a partir do segundo mês, de modo a permitir prever o ano de 2019 apenas com os dados observados até dezembro de 2018, tenha desempenho inferior às previsões atualizadas. Os modelos treinados para Petrolina produzem previsões com RMSE que variam de 0,6 a 1,59 °C (Sabino et al., 2018), resultados com RMSE semelhantes aos da presente pesquisa, conforme observa-se na Tabela 2.

Tabela 1. Configurações obtidas através do algoritmo genético para a rede neural artificial (RNA) do tipo *Multilayer Perceptron* (MLP) e respectivos indicadores estatísticos.

Previsão da Temperatura do ar	RNA-MLP	Indicadores Estatísticos	
		EAM ¹	RMSE ²
Máxima Média Mensal	MLP-10-15-0,50	0,55 °C	0,73 °C
Máxima diária	MLP-08-03-0,10	0,80 °C	1,10 °C
Mínima Média Mensal	MLP-11-12-0,80	0,37 °C	0,44 °C
Mínima diária	MLP-06-02-0,20	0,64 °C	0,81 °C

¹Erro Absoluto Médio (EAM); ²Raiz do Erro Quadrático Médio (RMSE).

Tabela 2. Desempenho das previsões da temperatura do ar para o ano de 2019.

Previsão da Temperatura do ar	RNA-MLP	Indicadores Estatísticos	
		EAM ¹	RMSE ²
Máxima Média Mensal Inicial	MLP-10-15-0,50	1,04 °C	1,18 °C
Máxima Média Mensal Atualizada	MLP-10-15-0,50	0,98 °C	1,16 °C
Máxima diária	MLP-08-03-0,10	0,75 °C	1,01 °C
Mínima Média Mensal Inicial	MLP-11-12-0,80	0,50 °C	0,56 °C
Mínima Média Mensal Atualizada	MLP-11-12-0,80	0,33 °C	0,45 °C
Mínima diária	MLP-06-02-0,20	0,64 °C	0,81 °C

¹Erro Absoluto Médio (EAM); ²Raiz do Erro Quadrático Médio (RMSE).

Outros estudos em diferentes locais, também, indicam bons resultados gerados pela RNA na estimativa da temperatura do ar: Jain et al. (2022) utilizaram RNA e MLR para prever a temperatura do ar. A RNA gerou resultados melhores na previsão de temperatura em comparação com MLR. Ustaoglu et al. (2008) empregaram três RNAs distintas para prever a temperatura média, máxima e mínima diária do ar na Turquia. Eles mostraram que todos os métodos de redes neurais utilizados produziram resultados satisfatórios. Chattopadhyay et al. (2011) aplicaram três tipos de RNAs (perceptron multicamadas (MLP), rede neural de alimentação generalizada (GFFNN) e rede neural modular (MNN) para prever a temperatura máxima mensal do ar no nordeste da Índia. Verificou-se que o modelo MNN que utiliza medições de temperatura do ar teve melhor desempenho que MLP e GFFNN.

As previsões de T_x e T_n diária quando transformadas em previsões de H_g diária tiveram resultados com $EAM = 0,79 \text{ kWh m}^{-2} \text{ dia}^{-1}$ e $RMSE = 1,04 \text{ kWh m}^{-2} \text{ dia}^{-1}$ no plano horizontal (Figura 4A). Já as previsões no plano faceado para o norte inclinado a 10° resultaram em $EAM = 0,81 \text{ kWh m}^{-2} \text{ dia}^{-1}$ e $RMSE = 1,06 \text{ kWh m}^{-2} \text{ dia}^{-1}$ (Figura 4B). Observa-se menor desempenho da metodologia proposta nos dias nublados, que se deve, muito provavelmente, a menor acurácia do modelo de Hargreaves & Samani (1982) para essa condição de céu.

As previsões de T_x e T_n média mensal atualizadas quando transformadas em previsões de irradiação solar global média diária de cada mês no plano horizontal obtêm valor previsto de $5,38 \text{ kWh m}^{-2} \text{ dia}^{-1}$ ($EAM = 0,32 \text{ kWh m}^{-2} \text{ dia}^{-1}$ e $RMSE = 0,37 \text{ kWh m}^{-2} \text{ dia}^{-1}$) contra o valor medido de $5,25 \text{ kWh m}^{-2} \text{ dia}^{-1}$ (Figura 5)

Previsão da irradiação solar global diária no plano horizontal (H_g) e orientado arbitrariamente ($H_g\beta\gamma^h$)




Figura 4. Irradiação solar global no plano horizontal prevista e observada diária (A), no plano faceado para o norte inclinado a 10° (B), no ano de 2019.




Figura 5. Irradiação solar global no plano horizontal prevista e observada média diária mensal, no ano de 2019.

Previsão e estimativa de energia elétrica gerada

Na realidade técnica atual, normalmente um sistema FV bem projetado e instalado, que utiliza módulos FV e inversores de boa qualidade, e que esteja em perfeitas condições de funcionamento tem um *Performance Ratio* (PR) mais ou menos de 80% (Antoniolli, 2015; Lagarde et al., 2023). A estimativa de geração utilizando a metodologia proposta com valores medidos obteve geração média anual de 21,53 kWh dia⁻¹ a um PR de 80,04%, este resultado é um forte indício que as

perdas no sistema fotovoltaico conectado à rede (SFVCR) estão sendo contabilizadas de forma fidedigna.

As previsões de temperatura do ar e irradiação solar global, quando transformadas em previsões de geração diária de energia obtêm desempenho de EAM = 3,25 kWh dia⁻¹ e RMSE = 4,28 kWh dia⁻¹ (Figura 6). Observa-se que a metodologia consegue acompanhar melhor os dias mais ensolarados e perde acurácia nos dias menos ensolarados.




Figura 6. Geração de energia prevista e estimada, no plano faceado para o norte inclinado a 10°, no ano de 2019.

As previsões de irradiação solar global horárias obtiveram desempenho de EAM = 0,39 kWh e RMSE = 0,54 kWh. As curvas das previsões e estimativas em um dia de céu claro (transmitância atmosférica, Kt de 0,62) e em um dia tendendo para céu nublado (Kt de 0,43) são observadas na Figura

7. A transmitância atmosférica ou índice de claridade é usado para caracterizar a condição do céu.




Figura 7. Energia Gerada prevista e estimada para dia com Kt de 62% (A), e para dia com Kt de 43% (B), no plano faceado para norte inclinado a 10°, no ano de 2019.

As previsões de irradiação solar global horária obtêm melhor desempenho em dias de céu

claro, pois além do modelo de Hargreaves & Samani (1982) a equação utilizada para distribuir o valor diário previsto no fotoperíodo é mais acurada nessas condições.

As previsões de geração de energia elétrica mensais obtiveram desempenho de $EAM = 36,17 \text{ kWh mês}^{-1}$ e $RMSE = 49,70 \text{ kWh mês}^{-1}$. Observa-se menor desempenho da metodologia proposta nos meses chuvosos da região de estudo, que se deve, principalmente, a erros de previsão para mais da temperatura do ar máxima média mensal no período, o que potencializou a característica do modelo de Hargreaves & Samani (1982) de superestimar a irradiação solar para condições de céu nublado, ou seja, para condição de céu predominante do período em questão. Na Tabela 3, o erro absoluto em termos percentuais (EAP) evidência melhor a menor acurácia da metodologia no trimestre mais chuvoso do ano (junho, julho e agosto).

A metodologia para previsão de geração de energia elétrica anual obteve média de geração anual de $21,85 \text{ kWh dia}^{-1}$ contra o valor estimado de $21,53 \text{ kWh dia}^{-1}$.

Tabela 3. Geração de energia elétrica mensal estimada e prevista no plano faceado para norte inclinado a 10°, no ano de 2019, com respectivos erros absoluto percentual.

Meses	Estimado (kWh)	Previsto (kWh)	EAP (%)
Janeiro	672,86	657,79	2,24
Fevereiro	686,80	619,24	9,84
Março	709,94	677,95	4,51
Abril	641,71	640,56	0,18
Maio	655,38	639,66	2,40
Junho	542,87	616,61	13,58
Julho	551,08	665,76	20,81
Agosto	634,02	697,74	10,05
Setembro	668,86	693,96	3,75
Outubro	727,06	718,50	1,18
Novembro	684,33	669,40	2,18
Dezembro	685,72	687,52	0,26
MÉDIA	655,05	665,39	5,91

Avaliação da melhor direção e inclinação dos módulos fotovoltaicos

No ano 2019, os dados de demanda (MWh/h), do SIN disponibilizadas pela ONS, apresentam curvas (Figura 8) com pico as 19:00 h na média horária anual e pico as 15:00 h para a

média horária dos meses de verão, entretanto nos dois períodos analisados há uma demanda relevante por energia elétrica às 15:00h.

A configuração com a maior nota de avaliação foi a de inclinação (β) 13,23° e azimuth (γ) 127,55° (direção próxima ao noroeste). Pesquisas evidenciam que pequenas variações (+/-

9°) do ângulo β afetam muito pouco a produção de eletricidade do sistema fotovoltaico ao longo do ano (Božiková et al., 2021; Prunier et al., 2023). Todavia, para otimização da produção de energia em um horário específico essas variações são consideráveis, como foi objetivado nessa presente pesquisa.

Com essa configuração estimou-se geração média diária anual de 21,19 kWh dia⁻¹, valor 1,58% menor que a geração no plano inclinado a 10° faceado para o norte, azimuth 180° (Norte) (Figura 9). Contudo a geração média anual estimada no período de maior demanda (15h) foi 32,84 % entre as duas configurações supracitadas (1,69 kWh e 1,27 kWh, respectivamente). Resultados de Souza et al. (2005) evidenciam que a irradiação solar

global horária é maior no período vespertino em relação ao matutino em Maceió-AL, os autores justificam que a irradiação é maior nesse período devido a maior nebulosidade que ocorre no período matutino em função da brisa marítima e intensidade das mudanças nos ventos alísios. Essas informações corroboram com a configuração de azimuth 127,55°, uma vez que nessa direção as placas os raios solares incidente relativamente mais perpendiculares no período da tarde.

Na Figura 9 observa-se que a curva de geração de energia elétrica com a configuração com a maior nota (curva em cor vermelha) apresenta um deslocamento para direita, o que significa maior produção de eletricidade no período vespertino.




Figura 8. Curvas de carga do Sistema Interligado Nacional no ano de 2019, disponibilizadas pelo Operador Nacional do Sistema Elétrico (ONS): A) horária média anual; B) horária média no verão do Brasil.




Figura 9. Geração de energia estimada média diária anual, nos planos $\beta = 10^\circ$; $\gamma = 180^\circ$ e $\beta = 13,23^\circ$; $\gamma = 127,55^\circ$, no ano de 2019.

Conclusões

1. A metodologia proposta para prever temperatura do ar é satisfatória, contudo, a previsão das temperaturas máximas médias mensais tem baixa acurácia e contribuem para a propagação de erros dentro do algoritmo de previsão de forma significativa.

2. As previsões de irradiação solar global são mais acuradas em dias de céu claro, as previsões em períodos mais nebulosos são prejudicadas pelo menor poder de estimativa do modelo de Hargreaves & Samani nessas condições.

3. A metodologia para estimar as perdas no SFVCR é satisfatória e adequada a realidade da região.

4. A previsão de geração de energia elétrica é melhor para janelas de tempo mais longas e condições de céu claro.

5. A configuração dos módulos FV que proporcionam a maior geração média anual aliada a maior geração média anual no período de maior demanda do SIN é de inclinação de $13,23^\circ$ e azimute de $127,55^\circ$.

Agradecimentos

A Eletrobras, CNPq, CAPES e FAPEAL pela disponibilidade de recursos para aquisição de equipamentos.

Referências

- ABSOLAR, Associação Brasileira de Energia Solar. Infográficos. Disponível: <https://www.absolar.org.br/mercado/infografico/>. Acesso em: 02, fevereiro de 2024.
- Antoniolli, A.F.G., 2015 Avaliação do desempenho de geradores solares fotovoltaicos conectados à rede elétrica no Brasil. Dissertação de mestrado. Departamento de Engenharia Civil, Universidade Federal de Santa Catarina – UFSC, Florianópolis – SC.
- Antonopoulos, V. Z., Papamichail, D. M., Aschonitis, V. G., Antonopoulos, A. V., 2019. Solar radiation estimation methods using ANN and empirical models. *Comput Electron Agric.* 160, 160-167. DOI: <https://doi.org/10.1016/j.compag.2019.03.022>
- Božiková, M., Bilčík, M., Madola, V., Szabóová, T., Kubík, L., Lendelová, J., Cviklovič, V., 2021. The Effect of Azimuth and Tilt Angle Changes on the Energy Balance of Photovoltaic System Installed in the Southern Slovakia Region. *Appl. Sci.* 11, 8998. DOI: <https://doi.org/10.3390/app11198998>.
- Chattopadhyay, S., Jhajharia, D., Chattopadhyay, G., 2011. Univariate modelling of monthly maximum temperature time series over northeast India: Neural network versus Yule-Walker equation based approach. *Meteorol. Appl.*, 18, 70-82. DOI: <https://doi.org/10.1002/met.211>.
- De Souza, J. L., Nicácio, R. M., Moura, M. A. L., 2005. Global solar radiation measurements in

- Maceio, Brazil. *Renew. Energy*. 30 (8), 1203-1220. DOI: <https://doi.org/10.1016/j.renene.2004.09.013>.
- EPE. Considerações Sobre o Comportamento do Consumidor: Documento de apoio ao PNE 2050. Rio de Janeiro, 2018. Disponível: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-227/topico-457/Comportamento%20do%20Consumidor.pdf>. Acesso: 08 fevereiro de 2023
- EPE. Balanço Energético Nacional 2023. Disponível: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/Balanco-Energetico-Nacional-2023>. Acesso: 10 janeiro de 2023.
- Frontin, S. O., Brasil, A. C. P., Carneiro, M. T. D., Godoy, N. R. D., 2017. Usina Fotovoltaica Jaíba Solar: Planejamento e Engenharia. Teixeira Gráfica e Editora LTDA, Brasília.
- Jain, S., Rathee, S., Kumar, A., Sambasivam, A., Boadh, R., Choudhary, T., Kumar, P., Singh, P. K., 2022. Prediction of temperature for various pressure levels using ANN and multiple linear regression techniques: A case study. *Materials Today: Proceedings*, 56 (1), 194-199. DOI: <https://doi.org/10.1016/j.matpr.2022.01.067>
- Hargreaves, G. H., Samani, Z. A., 1982. Estimating potential evapotranspiration. *Journal of Irrigation and Drainage Engineering*, 108, 225-230. DOI: <https://doi.org/10.1061/JRCEA4.0001390>.
- Holdermann, C., Kissel, J., Beigel, J., 2014. Distributed photovoltaic generation in Brazil: An economic viability analysis of small-scale photovoltaic systems in the residential and commercial sectors. *Energy Policy*. 67, 612–617. DOI: <http://dx.doi.org/10.1016/j.enpol.2013.11.064>.
- Iglesias, C., Vilaça, P., 2022. On the regulation of solar distributed generation in Brazil: A look at both sides. *Energy Policy*. 67, 113091. DOI: <https://doi.org/10.1016/j.enpol.2022.113091>.
- Iqbal, M., 1983. An introduction to solar radiation. NEW YORK: ACADEMIC PRESS.
- Jahani, B., Mohammadi, B.A., 2018. A comparison between the application of empirical and ANN methods for estimation of daily global solar radiation in Iran. *Theor Appl Climatol*. 137, 1257-1269. DOI: <https://doi.org/10.1007/s00704-018-2666-3>.
- Jang, J.S.R., Sun, C.T., Mizutani, E., 1997. Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence. *IEEE Trans Automat Contr*. 42(10), 1482-1484. DOI: <https://doi.org/10.1109/TAC.1997.633847>.
- Lagarde, G., Beillard, B., Mazen, S., Marie-Sandrine Denis, M-S., Leylaverne, J., 2023. Performance ratio of photovoltaic installations in France: Comparison between inverters and micro-inverters. *Journal of King Saud University - Engineering Sciences*, 35 (8), 531-538. DOI: <https://doi.org/10.1016/j.jksues.2021.11.007>.
- Jannuzzi, G., De Melo, C., 2012. Grid-connected photovoltaic in Brazil: policies and potential impacts for 2030. *Energy Sustain. Dev.* 17 (1), 40-46. DOI: <https://doi.org/10.1016/j.esd.2012.10.010>.
- Laudani, A., Lozito, G. M., Riganti Fulginei, F., 2021. Irradiance Sensing through PV Devices: A Sensitivity Analysis. *Sensors (Basel)*. 13, 4264. DOI: <https://doi.org/10.3390/s21134264>.
- Kaplan, Y.A., Saraç, M.S., Ünalı, G.G., 2022. Developing a new model in solar radiation estimation with genetic algorithm method. *Environ Prog Sustainable Energy*. 41, e13912. DOI: <https://doi.org/10.1002/ep.13912>
- Pereira, E. B., Martins, F. R., Gonçalves, A.R., Costa, R.S., Lima, F.L.; Rütther, R., Abreu, S.L., Tiepolo, G.M., Pereira, S.V., Souza, J.G., 2017. Atlas brasileiro de energia solar. 2.ed. São José dos Campos: INPE, 80p. DOI: <http://doi.org/10.34024/978851700089>
- Prunier, Y., Chuet, D., Nicolay, S., Hamon, G., Darnon, M., 2023. Optimization of photovoltaic panel tilt angle for short periods of time or multiple reorientations. *Energy Conversion and Management*: X. 20, 100417, [doi:10.1016/j.ecmx.2023.100417](https://doi.org/10.1016/j.ecmx.2023.100417).
- Sabino, E. R. C., Brennand, L. J. P., Barros, H. F., Vilela, O. C., Costa, A. C. A., 2018. Previsão de temperatura ambiente horária voltada para auxiliar previsões de geração de potência fotovoltaica. In: VII Congresso Brasileiro de Energia Solar, 2018, Gramado. VII Congresso Brasileiro de Energia Solar. DOI: <https://doi.org/10.59627/cbens.2018.659>
- Silva, D. D., Cardoso, E. M., Basquerotto, C., Pereira, J. A., Turra, A. E., Feldhaus, J. 2023. Outlook on the Brazilian scenario of floating photovoltaic solar energy, *Energy Reports*, 10, 4429-4435. Disponível: <https://doi.org/10.1016/j.egyr.2023.11.004>. Acesso: 16 de Jan. de 2024.
- Souza, J.L., Filho, G.M., Lyra, R.F.F., Teodoro, I., Santos, E.A., Silva, J.L., Silva, P.R.T., Cardim,

- A.H., Amorin, E.C., 2004. Análise da precipitação pluvial e temperatura do ar na região do tabuleiro costeiro de Maceió, AL. Período 1972–2001. Revista Brasileira de Agrometeorologia. V, 131-141. Disponível em: <https://www.sbagro.org/files/biblioteca/1420.pdf>. Acesso em 15 de março de 2023.
- Ustaoglu, B., Cigizoglu, H. K., Karaca, M., 2008. Forecast of daily mean, maximum and minimum temperature time series by three artificial neural network methods. Meteorol. Appl. 15, 431–445. DOI: <https://doi.org/10.1002/met.83>.
- Yohanna, J. K., Itodo, I. N., Umogbai, V.I., 2011. A model for determining the global solar radiation for Makurdi, Nigeria. Renew Energy. 36, 1989-1992. DOI: <https://doi.org/10.1016/j.renene.2010.12.028>