

# Methodology based on Artificial Neural Networks for Hourly Forecasting of PV Plants Generation

A. W. B. Silva, B. B. Freitas, C. L. A. Filho, C. D. Freitas, E. A. S. Junior, E. S. Castro, E. M. Araújo, F. I. F. Correia, F. R. P. Silva, J. J. S. Souza, L. L. P. Martins, L. R. R. Coutinho, N. P. L. Ces, R. Castelo, P. C. M. Carvalho and T. C. Carneiro

**Abstract**—We propose a methodology for the hourly forecast of the photovoltaic (PV) power of two plants (6.03 kWp and 7.37 kWp) installed in the metropolitan region of Fortaleza - CE. The methodology uses two Artificial Neural Networks (ANN) to predict time series: Perceptron type with Multiple Layers (MLP) and radial base functions (RBF), trained with historical data of hourly PV power collected during the year 2020 in the locations under study. System performance meters are applied (correlation coefficient - R, Nash-Sutcliffe efficiency - NSE and relative trend - VR). The data evaluated in each plant are treated using MLP and RBF networks, as well as the Persistence method, seeking to increase the study reliability. ANN results indicate potential to learn the behavior of the plants, with R above 80%, VR close to zero and NSE above 0.50 in two of the applications. In this specific case, despite being similar networks, MLP shows a higher accuracy than RBF.

**Keywords** —Artificial neural network, solar photovoltaic generation, multilayer perceptron, radial basis function

## I. INTRODUÇÃO

As fontes renováveis têm expandido sua participação na matriz energética mundial, impulsionadas por investimentos em pesquisa e desenvolvimento [1]. Dentre as opções se destaca o uso da fonte solar, que apresenta o maior incremento de capacidade instalada anualmente [2], justificado por fatores como o aumento do interesse nos mercados de energia sustentável, a redução da emissão de gases do efeito estufa e a diminuição dos custos dos sistemas fotovoltaicos (FV) [3,4].

Dentre os países com maior inserção da geração FV estão a China e países membros da Organização para a Cooperação e Desenvolvimento Econômico (OCDE), com destaque para os Estados Unidos, o Japão e a Alemanha [1].

Considerando fatores climáticos e geográficos, o Brasil apresenta altos níveis de irradiação e sua proximidade com a linha do Equador proporciona pouca variabilidade do recurso solar, entre as estações do ano [5]. Diante disso, ao longo dos últimos anos, a legislação federal e as estaduais apostam na diversificação da matriz energética, com maior presença das fontes de geração renováveis, em detrimento das fontes fósseis e seus derivados [6].

Nessa perspectiva, merecem destaque os leilões de energia organizados pela Agência Nacional de Energia Elétrica (ANEEL) e a Resolução Normativa nº 482/2012, que estabelece as condições gerais para o acesso de sistemas de micro e minigeração, ao sistema de distribuição de energia, bem como institui o sistema de compensação de energia elétrica [7,8].

Dentre as cinco regiões brasileiras, o Nordeste apresenta o maior potencial solar, tendo os valores médios diários totais da irradiação global horizontal e da componente direta normal na ordem de, respectivamente, 5,49 kWh/m<sup>2</sup> e 5,05 kWh/m<sup>2</sup> [9]. No contexto nordestino, 93% do território do Ceará (CE) estão no semiárido, que se caracteriza pela escassez e irregularidade pluviométrica, alta taxa de evaporação e elevada irradiância solar. Tais características são vantajosas para o uso da energia eólica e solar no estado [10]: de acordo com [11], o aproveitamento de 10% do potencial solar FV do CE superaria em 30 vezes a capacidade FV centralizada total atualmente instalada no Brasil (2,1 GW).

No CE encontram-se em operação oito empreendimentos de Geração Centralizada (GC) FV (218.000 kW), nove em construção (278.397 kW) e 52 (cinquenta e dois) com a construção não iniciada (1.942.756 kW), o que resulta em uma potência outorgada de 2.439.153 kW (dados referentes a 2021) [12]. Assim, o Estado encontra-se na 4ª posição no *ranking* nacional de potência outorgada para GC, sendo superado por Minas Gerais, Bahia e Pernambuco [12,13].

A.W.B. Silva, UFC, Ceará, Brasil, andrewagner10@yahoo.com.br.  
 B.B. Freitas, UFC, Ceará, Brasil, brenobf93@gmail.com.  
 C.L.A. Filho, UFC, Ceará, Brasil, cesarledioalencarfilho@gmail.com.  
 C.D. Freitas, UFC, Ceará, Brasil, claudivandfreitas@gmail.com.  
 E.A.S. Junior, UFC, Ceará, Brasil, elderasj@alu.ufc.br.  
 E.S. Castro, UFC, Ceará, Brasil, erasmocastro@ufc.br.  
 E.M. Araújo, UFC, Ceará, Brasil, esdrasma@alu.ufc.br.  
 F.I.F. Correia, UFC, Ceará, Brasil, israel.correia@hotmail.com.  
 F.R.P. Silva, UFC, Ceará, Brasil, renatoponte@icloud.com.  
 J.J.S. Souza, UFC, Ceará, Brasil, janieresouza@dee.ufc.br.  
 L.L.P. Martins, UFC, Ceará, Brasil, laiglou@chef.gov.br.  
 L.R.R. Coutinho, UFC, Ceará, Brasil, rodolfoforcoutinho@ufc.br.  
 N.P.L. Ces, UFC, Ceará, Brasil, nataliapimentelbr@hotmail.com.  
 R. Castelo, UFC, Ceará, Brasil, ricardo.castelo77@gmail.com.  
 P.C.M. Carvalho, UFC, Ceará, Brasil, carvalho@dee.ufc.br.  
 T.C. Carneiro, UFC, Ceará, Brasil, tatiane.carolyne@ufma.br

Diante da expansão de sistemas FV e tendo em vista a intermitência do recurso solar, a utilização de plantas híbridas tem se tornado uma tendência [15]. Para uma avaliação eficiente na previsão de geração são necessários dados confiáveis de irradiância horizontal total (*Global Horizontal Irradiance* - GHI) e de geração FV [16], bem como métodos mais adequados para cada etapa, visto a complexidade e a necessidade de capturar a não linearidade dos dados de entrada no sistema de previsão [17].

Desse modo, o presente artigo tem como objetivo propor uma metodologia baseada em redes neurais artificiais (RNA) para previsão horária da geração de plantas FV descentralizadas instaladas na região metropolitana de Fortaleza – CE, como estudo de caso.

Além da seção introdutória, o artigo se organiza da seguinte forma: a Seção 2 apresenta o estado da arte sobre aplicações de RNA no setor FV. A Seção 3 apresenta referência teórica sobre as redes MLP e RBF. Na Seção 4 são apresentadas características dos sistemas FV utilizados, bem como é detalhada a aplicação das redes MLP e RBF para previsão de geração. Na Seção 5 são apresentadas as discussões dos resultados obtidos após a implementação das RNA. Por fim, na Seção 6 são apresentadas as principais conclusões.

## II. APLICAÇÕES DAS RNA NO SETOR FV

Em uma revisão de aplicações de RNA para diagnóstico e detecção de falhas em sistemas FV foram encontradas as principais tendências e os desafios do uso dessas redes. Em [18] apresentam-se trabalhos que provam a eficiência das redes para praticamente todos os tipos de falhas, chegando a uma taxa de sucesso superior a 90%. Entre os tipos de redes mais utilizados estão: RNA *Perceptron* com Múltiplas Camadas (*Multilayer Perceptron* - MLP) e a Convolutiva (*Convolutional Neural Network* - CNN).

Em [19] é proposto um algoritmo de detecção de falhas para sistemas FV baseado na Função de Base Radial (*Radial Basis Function* - RBF), onde é desenvolvido, implantado e validado um sistema de detecção de falhas, necessitando apenas de dois parâmetros como entrada para a RNA: irradiância e potência FV. A RNA é testada em outro sistema FV, permitindo avaliar o comportamento da RNA com e sem sombreamento. O processo de validação fornece uma precisão de detecção de falhas acima de 97%.

O algoritmo *Grey Wolf Optimizer* (GWO) é utilizado combinado com o algoritmo MLP para previsão de GHI diária em [20]. O conjunto de dados utilizados inclui radiação solar horizontal difusa (*Diffuse Horizontal Irradiance* - DHI), umidade relativa e temperatura do ar. Na análise, a GHI é utilizada como variável de saída, enquanto as demais grandezas são utilizadas como variáveis de entrada. O algoritmo é testado para três funções de ativação: sigmóide, seno e tangente hiperbólica; a melhor *performance* é obtida para a função sigmóide, com entradas DHI, umidade relativa e temperatura do ar. Para esta função é obtido um erro percentual médio absoluto (*Mean Absolute Percentage Error* - MAPE) de 3,025%, um erro médio absoluto (*Mean Absolute Error* - MAE) de 0,022 e um coeficiente de determinação (CD) de 0,9786.

Em [21] uma RNA do tipo MLP é usada na predição da irradiação global média diária. O modelo computacional proposto é avaliado com a incorporação das variáveis de médias diárias da temperatura, umidade, ponto de orvalho, pressão e velocidade do vento. O desempenho do modelo é avaliado através do MAE, erro médio quadrático (MSE), MAPE, raiz do erro médio quadrático (*Root Mean Square Error* - RMSE) e índice de confiança (IC). A configuração da rede MLP com duas camadas ocultas e número de neurônios (5,1), respectivamente, apresenta desempenho de 87,92% no conjunto de validação em termos do IC.

Uma revisão das aplicações das RNA como um método baseado em sistemas inteligentes para otimizar e prever o desempenho de dispositivos com uso de energia solar é encontrada em [22]. São discutidos brevemente os tipos de RNA comumente utilizados para essas aplicações, tais como a RBF e a Rede Neural de Elman (RNE). Além disso, são destacados diferentes critérios estatísticos utilizados para avaliar o desempenho de uma RNA.

Em [23] é feita uma revisão e um comparativo entre RNA e métodos estatísticos de série temporal, métodos físicos e métodos de conjunto para previsão da geração FV. São analisadas RNA e *Support Vector Machine* (SVM) devido à sua capacidade de resolver modelos de previsão complexos e não lineares. A avaliação mostra que os modelos de Inteligência Artificial (IA) podem diminuir o erro, em comparação com outras abordagens estatísticas, o que reforça a efetividade da IA nos estudos de previsão FV.

Um sistema baseado em RNA é proposto em [24] para estimar a potência máxima de um módulo FV de baixa concentração (*Low-concentrating Photovoltaic* - LCPV). O modelo considera os principais parâmetros que influenciam a produção elétrica: irradiância direta e difusa, temperatura do módulo e os ângulos de incidência transversal e longitudinal.

A produção FV é medida por um ano em [25]. Modelos matemáticos neurais, como redes *feedforward* generalizadas (GFF), MLP, SOM (*Self-organizing Maps*) e SVM, são implementados para simular e prever a saída dos sistemas FV. SOM apresenta o menor valor de MSE na fase de treinamento (0,0638) entre as redes, tendo percentual de acerto de 78,55%. SOM apresenta um valor MAPE menor que 5,339, sendo que todos os modelos têm RMSE de cerca de 0,25.

A RNA usa o prognóstico da irradiação solar global através dos dados obtidos do Sistema de Organização Nacional de Dados Ambientais (SONDA) em [26]; um dos métodos é o MLP, que determina a irradiância em um local de interesse.

Comparando MLP e RBF em [27], é verificado que a MLP apresenta um melhor resultado em previsão da irradiação; porém, para entradas diferentes, a RBF tem um desempenho melhor. Para obter os níveis de desempenho e precisão são usados MSE, MAPE e Fração de Variância Absoluta ( $R^2$ ); o local de estudo é Teerã, Irã. MLP é aplicado com horas de sol, temperatura máxima e mínima, média relativa de umidade, velocidade média do vento, irradiação em céu nublado e ensolarado e a quantidade de material particulado como parâmetros de entrada e, para saída, a irradiação solar global.

Uma RBF é aplicada em [28] para previsão da GHI em Medina, Arábia Saudita, utilizando dados meteorológicos, como temperatura do ar, horas de sol pleno e umidade relativa. Quatro modelos RBF são propostos: o primeiro utiliza como

parâmetros de entrada horas de sol pleno e dia do ano, o segundo utiliza os mesmos parâmetros mais a temperatura do ar, o terceiro adiciona a umidade relativa e o quarto modelo usa os mesmos parâmetros do terceiro, excluindo a horas de sol pleno. Com isso, são obtidos valores medidos e previstos próximos de irradiação solar diária global, tendo o segundo modelo o melhor desempenho, com coeficiente de correlação (CC) de 98,80%, erro médio percentual (*Mean Percentage Error* - MPE) de 1,7501 e MSE de 0,013101.

Em [29] é apresentado um método prático para previsão de irradiação em um período de 24 horas em uma planta FV em Trieste, Itália. A RNA da aplicação é MLP; são utilizados os valores diários de irradiação solar e temperatura do ar. Os resultados mostram que o modelo proposto alcança CC na faixa de 98-99%, para dias ensolarados, e de 94-96%, para dias nublados. O método é validado comparando os valores teóricos de produção que seriam obtidos na previsão com a energia elétrica produzida pela planta FV conectada à rede.

Uma revisão de vários métodos de IA é encontrada em [30], onde testes com MLP e RBF, bem como métodos de previsão, são validados por meio de aplicações em dimensionamento de sistemas FV. Com isso, constata-se a eficiência das RNA, em que o erro relativo (ER) não ultrapassa 6%; ambas as redes neurais funcionam de forma eficiente, tanto para uma avaliação independente, quanto para desenvolver IA mais elaboradas quando combinadas.

Em [31] é proposta uma RNA para a previsão de tensão e corrente de um sistema FV autônomo no sul da Argélia. A RNA proposta combina o algoritmo de Levenberg-Marquardt (LM) com um filtro de resposta ao impulso infinito (*Infinite Impulse Response* - IIR), sendo denominada LM-IIR. Dentre as arquiteturas de RNA testadas (MLP, RBF e LM-IIR), os melhores resultados são obtidos pelo modelo LM-IIR, apresentando NMSE de 0,0034 e CC de 96% para o modelo global, que inclui todos os componentes do sistema.

RBF é usada em [32] para obtenção eficaz de dados estimados de GHI; os resultados obtidos por este modelo, que apresenta um ER médio de 1,34%, são capazes de prever e estimar uma cadeia de dados diários de irradiação solar com apenas os dados iniciais, de fácil obtenção. No entanto, este modelo apresenta limitações para a convergência de dados de mais de 300 amostras, tornando-se um processo lento.

Em [33] utiliza-se MLP com uma arquitetura baseada em uma camada de cinco entradas e uma oculta. O processo de aprendizagem usa, como técnica de obtenção dos dados, o algoritmo de retropropagação. No caso da RBF, a arquitetura consiste de uma camada de entrada, uma de saída e uma oculta, caracterizando-se por uma resposta que diminui monotonicamente com a distância de um ponto central de dados. O intervalo de erros é de 0,83 a 10,08 MJ/m<sup>2</sup>/dia para a RBF e de 11,01 a 9,41 MJ/m<sup>2</sup>/dia para a MLP.

A Tabela I apresenta as informações dos artigos utilizados na presente revisão de literatura, de forma resumida.

TABELA I.  
RESUMO DAS INFORMAÇÕES DOS ARTIGOS DA REVISÃO DE LITERATURA.

Autor	Rede Neural	Objetivo	Erro
[18]	MLP-CNN	Avaliação de dimensionamento e identificação de falhas em sistemas FV.	Não se aplica
[19]	RBF	Avaliação de desempenho de uma RBF aplicada em dois sistemas FV.	Precisão = 97% MAPE = 3,025% MAE = 0,022 CD = 0,9786
[20]	GWO-MLP	Previsão de GHI diária.	MAE = 0,0598 MSE = 0,0063 RMSE = 0,0792 IC = 87,92%
[21]	RNA-MLP	Previsão da GHI.	Não se aplica
[22]	RBF-RNE	Revisão de aplicações FV e das RNAs utilizadas para prever o desempenho de dispositivos.	Não se aplica
[23]	RNA-SVM	Comparação de desempenho e precisão de previsão entre RNA e métodos estatísticos.	Não se aplica
[24]	MLP, RBF, ANFIS	Estimativa de potência máxima de módulos FV LCPV.	Não se aplica MAPE = 5,339% MSE = 0,0638 RMSE = 0,2539
[25]	MLP	Previsão de Produção de Sistema FV.	MAPE = 18,24% MAE = 19,88 REMPQ = 4,56% MAPE = 3,13
[26]	MLP	Previsão da GHI.	RMSE = 0,077 R <sup>2</sup> = 0,97 CC = 98,80%
[27]	MLP	Previsão da GHI.	MPE = 1,7501 MSE = 0,013101
[28]	RBF	GHI de um sistema FV autônomo.	MAE < 5%
[29]	MLP	Previsão de irradiação.	ER < 6%
[30]	MLP, RBF e RNN	Avaliação de eficiência no dimensionamento FV comparando com RNA.	NMSE = 0,0034
[31]	MLP, RBF e LM-IIR	Uso do algoritmo LM-IRR para modelagem e previsão de SVA.	MRE(%) = 1,34
[32]	RBF	GHI Diária.	RBF(%) = 0,83
[33]	RBF e MLP	GHI Diária.	MLP(%) = 1,01

### III. EMBASAMENTO TEÓRICO

#### A. Perceptron com Múltiplas Camadas

As RNAs do tipo MLP surgem como alternativa à resolução de problemas não-lineares, os quais as redes neurais, tais como a *Perceptron* de uma única camada e a *Adaline*, não conseguiram solucionar. A maioria dos problemas e situações reais apresenta como característica a não-linearidade; essas não-linearidades são incorporadas aos modelos neurais, por meio das funções de ativação (não-lineares) de cada neurônio da rede e da composição da sua estrutura em camadas sucessivas [34]. As RNA-MLP são sistemas de neurônios ligados por conexões sinápticas, com uma ou mais camadas ocultas e com uma camada de saída, como visto na Fig. 1.

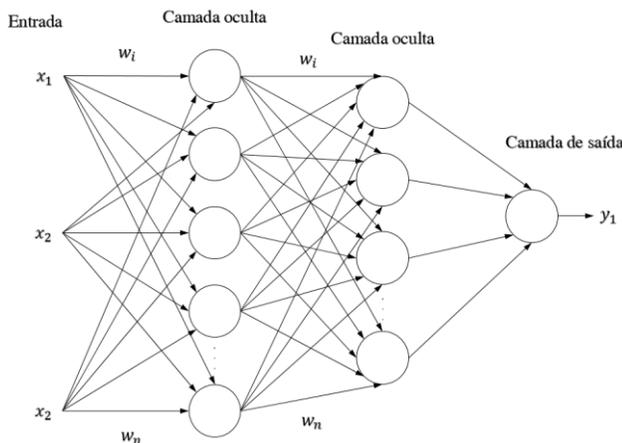


Fig. 1. Arquitetura de uma rede do tipo MLP [35].

A rede MLP é do tipo *feedforward*, ou seja, nenhuma saída de um neurônio de uma camada  $k$  será sinal de entrada para um neurônio de uma camada menor ou igual a  $k$ ; além disso, é completamente conectada, tal que cada neurônio fornece sua saída para cada unidade da camada seguinte, sendo  $k$  uma constante que o mapeamento entre a entrada e a saída é determinado por meio de uma função de ativação dada pela (1) [35].

$$f(u_i) = Y_i = \frac{1}{(1 + \exp(-ku_i))} \quad (1)$$

#### B. Função de Base Radial

RBF é uma rede de multicamadas com uma camada de nós de entrada (nós sensoriais), uma camada de nós escondidos e uma camada de saída. Na RBF, a ativação de um nó é função da distância entre seus vetores de entrada e seus respectivos pesos. As funções de transferência entre a camada de entrada e a camada escondida são não-lineares e aquelas que conectam a camada escondida com a camada de saída são lineares [36,37].

Na saída, os parâmetros ajustáveis são os pesos de uma combinação linear, que podem ser determinados utilizando o método dos mínimos quadrados. As redes RBF constroem aproximações locais para mapeamentos entrada-saída, resultando em um aprendizado mais rápido e sensibilidade reduzida à ordem de apresentação dos dados do conjunto de treinamento.

Seja um número inteiro  $P$ , menor que um número de dados de treinamento  $N$ , obtém-se a (2), que fornece a saída da rede neural, apresentada na Fig. 2 [35,38].

$$y = \sum_{k=0}^P w_k \varphi(x; t_k) + w_0 \quad (2)$$

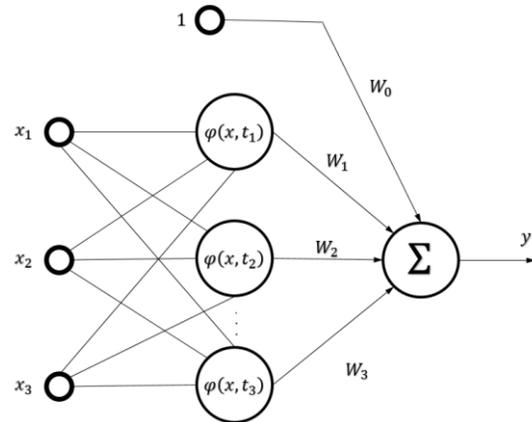


Fig. 2. Arquitetura de uma rede do tipo RBF [38].

Representando os centros das funções de base radial, está a variável  $t_k$ . Utilizando a regularização para o treinamento da rede RBF, a (3) mostra a função custo  $\varepsilon_r$  a ser minimizada.

$$\varepsilon_r = \sum_{i=1}^N (d_i - f(x_i))^2 + \sum_{j=1}^P \lambda_j w_j^2 \quad (3)$$

A variável  $d$  pode ser expressa por  $[d_1, d_2, \dots, d_n]^T$ , que representa o vetor de respostas desejadas. A variável  $w$  pode ser expressa como  $[w_0, w_1, w_2, \dots, w_p]^T$ , e representa o vetor de pesos da rede neural RBF. O parâmetro de regularização é  $\lambda_j$ , e  $f(x_i)$  é a saída da rede para um vetor de entrada  $x_i$  [36,38].

O número de nós na camada intermediária pode ser definido como igual ao número de padrões de entrada; assim, cada centro é situado sobre um vetor de entrada e a RBF mapeia com exatidão o vetor de entrada para a saída. A interpolação exata pode ser indesejada, principalmente quando houver ruído, o qual leva ao *overfitting*, em que não se consegue ter uma boa generalização, ou seja, extrapolação para novos dados [36,37,38].

### IV. METODOLOGIA

#### A. Coleta e Análise de Estatística dos Dados

Os dados utilizados no presente artigo são de geração elétrica diária (kWh) de duas plantas FV instaladas na região metropolitana de Fortaleza – CE, mais especificamente, no bairro Maraponga (de 6,03 kWp) e em Aquiraz (de 7,37 kWp).

A avaliação do comportamento das plantas FV é feita a partir das seguintes métricas: Produtividade (relação entre a eletricidade gerada e a potência instalada da planta) e Fator de Capacidade (relação entre a eletricidade gerada em um período e a capacidade de geração nominal da planta neste mesmo período).

### B. Detalhamento das Metodologias

Os modelos MLP e RBF são responsáveis pela estimativa de valores horários de potência para as duas plantas FV mencionadas. Inicialmente, os dados são preparados; essa etapa envolve, entre outros aspectos, a forma de aquisição, o pré-processamento, a normalização e a definição dos conjuntos de treino e de teste. Os dados são normalizados utilizando a normalização linear, deixando os dados entre 0 e 1, para serem aplicados, de forma adequada, às funções de ativação.

Nas duas aplicações, em ambas as localidades, os dados são separados em 80% para o conjunto de treinamento e 20% para o conjunto de teste; os dados de teste são compostos por dados em intervalos de tempo diferentes e totalmente independente daqueles utilizados para treinamento do modelo.

- **Multiple Layers Perceptron (MLP)**

A arquitetura da MLP apresentada na Fig. 3 é formada por uma camada de entrada, uma oculta e uma de saída. A camada inicial é composta por cinco entradas, que são as potências históricas (em W): a) P(t-4); b) P(t-3); c) P(t-2); d) P(t-1); e e) P(t). Realizando simulações com diferentes atrasos de tempo (2, 3 e 4), foram obtidos os melhores resultados com 4 atrasos de tempo, por isso a escolha de cinco entradas nas duas redes. O número de neurônios na camada oculta é obtido através do processo de tentativa e erro. Os melhores resultados foram obtidos com quatro neurônios na camada oculta. A camada de saída é composta por um único neurônio, o valor da potência P(t+1).

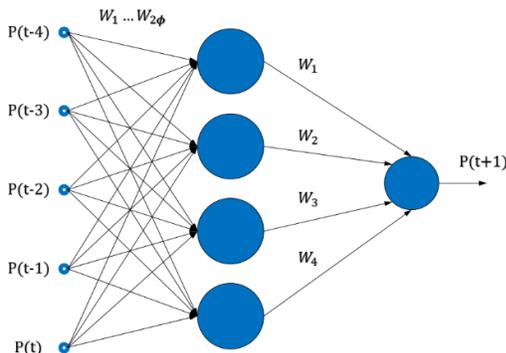


Fig. 3. Arquitetura da RNA MLP implementada.

O treinamento da MLP foi dividido em duas etapas principais: a primeira é a *forward* (propaga os sinais por toda a rede, da entrada para a saída), etapa onde a saída da rede é gerada e um erro é calculado; seguida da etapa de *backward* (erros são retropropagados da saída para a entrada) [34]. São utilizadas funções de ativação sigmóides para os neurônios da camada oculta e da camada de saída.

O princípio da retropropagação é o uso do gradiente descendente para estimar o erro nas camadas intermediárias, bem como o efeito que esses erros têm no erro da camada de saída. O erro da camada de saída é calculado e, na sequência, retropropagado para as camadas anteriores, permitindo o ajuste dos pesos proporcionais aos valores das conexões entre as camadas.

- **Radial base functions (RBF)**

O treinamento da RBF é realizado em dois estágios: no primeiro, o número de funções de base radial é estimado e seus parâmetros (centro e dispersão) são definidos por

aprendizado não supervisionado. O segundo estágio ajusta os pesos dos neurônios de saída. A arquitetura aplicada neste estudo é formada por uma camada de entrada, uma camada oculta e uma camada de saída (Fig.4).

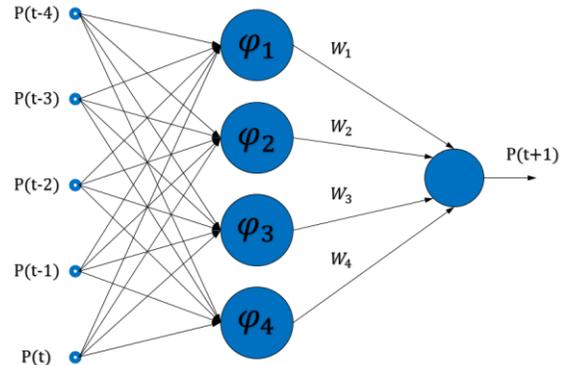


Fig. 4. Arquitetura da RNA RBF implementada.

A camada de entrada é composta por cinco entradas, que são as potências históricas: a) P (t-4); b) P (t-3); c) P (t-2); d) P (t-1); e e) P (t). O número de neurônios na camada oculta é obtido através do processo de tentativa e erro, chegando a 4 neurônios ( $\phi_1$ ,  $\phi_2$ ,  $\phi_3$  e  $\phi_4$ , onde cada neurônio tem uma função de base radial). A camada de saída é composta por um único neurônio, em ambas as aplicações, que é o valor da potência em W, P (t + 1). Em (4) e (5) foram consideradas usando a função gaussiana.

$$\varphi = \exp\left(-\frac{r^2}{2\sigma^2}\right) \quad (4)$$

$$r = ||x - t|| \quad (5)$$

Onde  $\varphi$  é a saída de cada neurônio da camada oculta;  $r$  é a diferença entre a entrada  $x$  e o centro  $t$ ; e  $\sigma$  é a medida da dispersão da curva.

A saída do RBF é formada por um único neurônio linear e seu cálculo é realizado por meio da (6).

$$y = \sum w_j \varphi_j \quad (6)$$

Onde  $y$  é a saída da RNA e  $w$  é o peso.

A avaliação do desempenho dos modelos MLP e RBF para estimativa da potência das duas plantas foi realizada com base nos seguintes índices: correlação ( $R$ ), viés relativo ( $VR$ ) e coeficiente de eficiência do modelo Nash-Sutcliffe ( $NSE$ ), descritos de (7) a (9) [39].

$$R = \frac{\sum_{i=1}^N (X_i - X_{med}) \cdot \sum_{i=1}^N (Y_i - Y_{med})}{\sqrt{\sum_{i=1}^N (X_i - X_{med})^2 \cdot \sum_{i=1}^N (Y_i - Y_{med})^2}} \quad (7)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (Y_i - X_i)^2}{\sum_{i=1}^N (X_i - X_{med})^2} \quad (8)$$

$$VR = \frac{X_{med} - Y_{med}}{Y_{med}} \quad (9)$$

Onde  $X_{med}$  é o valor médio do conjunto de dados observados,  $Y_i$  é o valor previsto,  $Y_{med}$  é o valor médio do conjunto de dados previstos e  $N$  é o número total de dados previstos. A dependência linear entre as previsões e os valores observados de potência é medida pela  $R$ .  $VR$  informa se

houver uma tendência a subestimar ou superestimar as potências observadas. O *NSE* expressa aderência entre dados previstos e observados. Uma previsão precisa teria  $R=1$ ,  $NSE=1$  e  $VR=0$ .

Além das RBF e MLP foi testado o modelo de persistência, descrito em (10), que usa a média móvel simples em que a previsão é a média das  $N$  observações mais recentes de uma série temporal, metodologia frequentemente utilizada para previsão de curto prazo.

$$P(t) = \frac{1}{N} \sum_{i=1}^N P(t-i) \quad (10)$$

## V. RESULTADOS E DISCUSSÕES

As Fig. 5 e 6 comparam as potências previstas com a RNA-MLP e os correspondentes valores observados para as duas localidades analisadas. Estes gráficos mostram os resultados para uma janela de 120 horas do período de testes (iniciando no pico de meio dia), ou seja, para uma série de dados totalmente independente daqueles utilizados para treinamento do modelo.

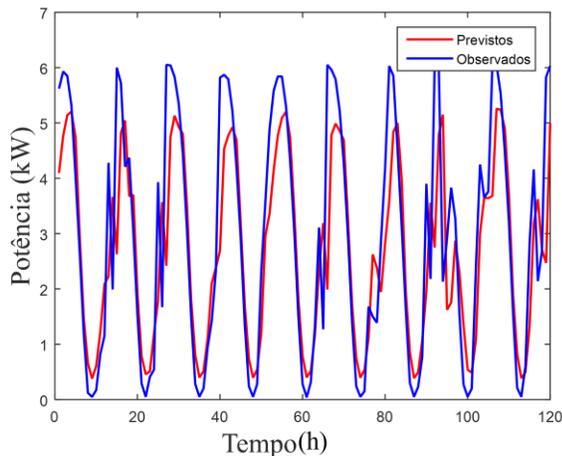


Fig. 5. Dados previstos e observados para um período de 120 horas (MLP - Aquiraz).

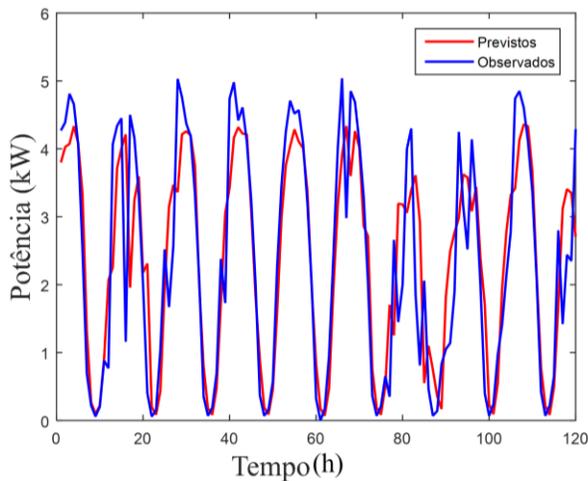


Fig. 6. Dados previstos e observados para um período de 120 horas (MLP - Maraponga).

As Fig. 7 e 8 comparam as potências previstas a RNA-RBF e os correspondentes valores observados para as duas localidades analisadas.

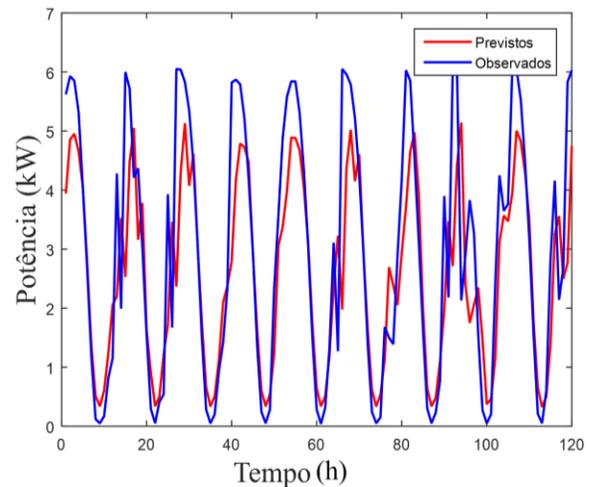


Fig. 7. Dados previstos e observados para um período de 120 horas (RBF - Aquiraz).

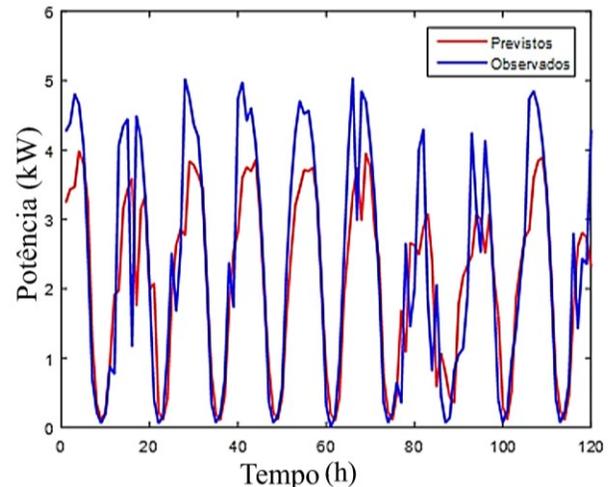


Fig. 8. Dados previstos e observados para um período de 120 horas (RBF - Maraponga).

As Figs. 9 e 10 mostram os resultados obtidos para o modelo de persistência nas duas localidades.

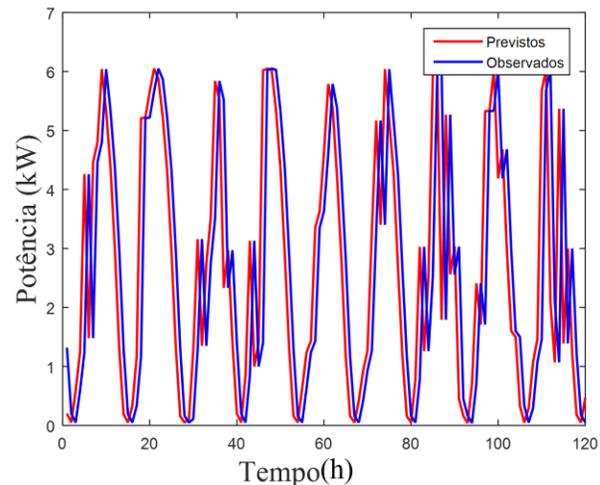


Fig. 9. Dados previstos e observados para um período de 120 horas (Persistência - Aquiraz).

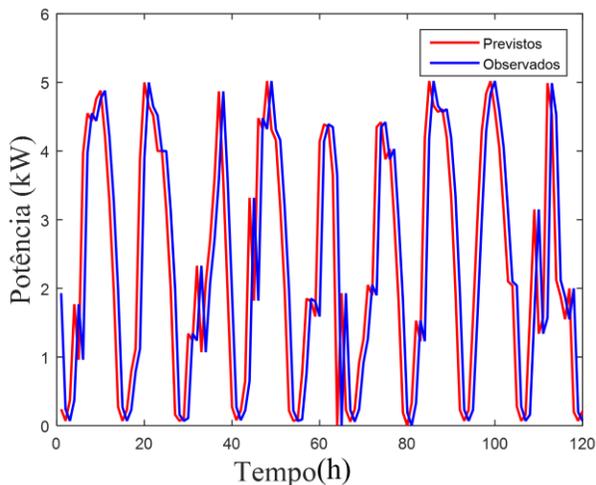


Fig. 10. Dados previstos e observados para um período de 120 horas (Persistência - Maraponga).

A Tabela II apresenta as métricas utilizadas para avaliação dos resultados.

	NSE	VR	R
Aquiraz – MLP	0,6516	-0,0686	0,8934
Aquiraz – RBF	0,3907	-0,1065	0,9048
Aquiraz – Persistência	0,4617	-4,8094e-04	0,7307
Maraponga – MLP	0,5763	-0,0028	0,8920
Maraponga – RBF	0,3520	-0,1078	0,8862
Maraponga – Persistência	0,3875	-4,8094e-04;	0,6935

Considerando as informações dos parâmetros R, NSE e VR, as redes MLP são superiores em termos de precisão às redes RBF e ao modelo de persistência; independentemente do tipo de RNA, as duas apresentam dificuldades em atingir os picos de geração.

## VI. CONCLUSÃO

O presente trabalho apresenta uma metodologia baseada em RNAs do tipo MLP e RBF aplicada à previsão de geração horária FV de plantas instaladas na Região Metropolitana de Fortaleza.

Através dos resultados apresentados, percebe-se que as redes MLP e RBF apresentam potencial para previsão de potência. MLP apresenta resultados superiores à RBF e ao modelo de persistência nas duas plantas FV, apresentando em Aquiraz e Maraponga os seguintes resultados: NSE=0,6516, VR=-0,0686 e R=0,8934; e NSE=0,5763, VR=-0,0028 e R=0,8920, respectivamente.

É observada uma dificuldade em atingir os picos de geração, que pode estar relacionada à limitação do conjunto de dados utilizado. Tal dificuldade pode vir a ser reduzida a medida que mais dados da série histórica venham a ser utilizados no treinamento das redes. Embora MLP e RBF sejam *feed-forward* não lineares e aproximadores universais, na presente aplicação específica MLP apresenta uma maior precisão.

## AGRADECIMENTOS

P. C. M. Carvalho agradece ao CNPq pela bolsa de pesquisador concedida. Breno B. Freitas agradece à FUNCAP pela bolsa de mestrado concedida. C. D. Freitas e N. P. L. Ces agradecem ao CNPq pela bolsa de mestrado concedida. L. R. R. Coutinho agradece à UFC pela liberação para dedicação ao doutorado. Os autores agradecem à Solamerica Energia pelos dados disponibilizados à pesquisa.

## REFERÊNCIAS

- [1] INTERNATIONAL ENERGY AGENCY. Key World Statistics 2020. Disponível em: <<https://www.iea.org/reports/key-world-energy-statistics-2020>>. Acesso em: 15 fev. 2021.
- [2] INTERNATIONAL RENEWABLE ENERGY AGENCY. Solar Energy Data. Disponível em: <<https://www.irena.org/solar>>. Acesso em: 15 fev. 2021.
- [3] A. Jha, P. P. Tripathy. Heat transfer modeling and performance evaluation of photovoltaic system in different seasonal and climatic conditions. *Renewable Energy*. vol. 135, pp. 856–865, 2019. DOI: 10.1016/j.renene.2018.12.032
- [4] M. A. T. Lira, M. L. S. Melo, L. M. Rodrigues, T. R. M. Souza. Contribuição dos Sistemas Fotovoltaicos Conectados à Rede Elétrica para a Redução de CO<sub>2</sub> no Estado do Ceará. *Revista Brasileira de Meteorologia*. vol. 34, no. 3, pp. 389-397, 2019. DOI: 10.1590/0102-7786343046
- [5] E. R. Gobbo, M. A. T. F. Silva, R. B. Bone. Do Petróleo à Energia Fotovoltaica: A Inserção do Brasil Neste Novo Mercado. VII Congresso Brasileiro De Energia Solar. Gramado, 2018.
- [6] M. Tolmasquim. NOVO MODELO DO SETOR ELÉTRICO BRASILEIRO. 2. ed. Rio de Janeiro: Synergia Editora, 2015. 310 p.
- [7] R. B. Braga. SETOR ELÉTRICO BRASILEIRO: visão crítica da geração de energia. Belo Horizonte: D'Plácido, 2016. 362 p.
- [8] AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL. Resolução Normativa ANEEL no 482: Estabelece as condições gerais para o acesso de microgeração e minigeração distribuída aos sistemas de distribuição de energia elétrica, o sistema de compensação de energia elétrica, e dá outras providências. Brasília, 2012.
- [9] Atlas Eólico e Solar: Ceará. Fortaleza: ADECE; FIEC; SEBRAE, 2019. 188 p. Disponível em: <<http://atlas.adece.ce.gov.br/ebook/mobile/index.html>>. Acesso em: 09 fev. 2021.
- [10] S. J. C. Vieira, L. G. T. Carpio. The economic impact on residential fees associated with the expansion of grid-connected solar photovoltaic generators in Brazil. *Renewable Energy*. vol. 59, pp. 1084-1098, 2020. DOI: 10.1016/j.renene.2020.06.016
- [11] F. R. Martins *et al.* Atlas brasileiro de energia solar. 2. ed. São José dos Campos: Inpe, 2017. 80 p. Disponível em: <<https://repositorio.unifesp.br/handle/11600/58353>>. Acesso em: 10 fev. 2021.
- [12] INSTITUTO DE PESQUISA E ESTRATÉGIA ECONÔMICA DO CEARÁ. IPECE Informa - Panorama da produção de energia elétrica no Estado do Ceará: Um enfoque para a matriz eólica. 141. ed. Fortaleza: Ipece, 2018. 33 p. Disponível em: <[https://www.ipece.ce.gov.br/wp-content/uploads/sites/45/2018/12/ipece\\_informa\\_141\\_12\\_Dez2018.pdf](https://www.ipece.ce.gov.br/wp-content/uploads/sites/45/2018/12/ipece_informa_141_12_Dez2018.pdf)>. Acesso em: 09 fev. 2021
- [13] ASSOCIAÇÃO BRASILEIRA DE ENERGIA SOLAR FOTOVOLTAICA (São Paulo). Energia Solar Fotovoltaica no Brasil: Infográfico ABSOLAR. Infográfico ABSOLAR. 2021. Disponível em: <<http://www.absolar.org.br/infografico-absolar.html>>. Acesso em: 09 fev. 2021.

- [14] INSTITUTO DE PESQUISA E ESTRATÉGIA ECONÔMICA DO CEARÁ. IPECE Informa - Desempenho do comércio exterior do Ceará em 2020: Primeiro ano da pandemia causada pela Covid-19. 188. ed. Fortaleza: IPECE, 2021. 15 p. Disponível em: <[https://www.ipece.ce.gov.br/wp-content/uploads/sites/45/2021/02/ipece\\_informe188\\_05\\_fev2021.pdf](https://www.ipece.ce.gov.br/wp-content/uploads/sites/45/2021/02/ipece_informe188_05_fev2021.pdf)>. Acesso em: 09 fev. 2021.
- [15] D. N. Araujo *et al.* Renewable Hybrid Systems: Characterization and Tendencies. *IEEE Latin America Transactions*. vol. 18, Issue 1, pp. 102-112, 2020. DOI: 10.1109/TLA.2020.9049467
- [16] J. F. Pessanha, A. Melo, J. Falcão. An Approach for Data Treatment of Solar Photovoltaic Generation. *IEEE Latin America Transactions*. vol. 18, Issue 9, pp. 1563-1571, 2020. DOI: 10.1109/TLA.2020.9381798
- [17] E. D. Obando, S. X. Carvajal, J. P. Aguledo. Solar Radiation Prediction Using Machine Learning Techniques: A Review. *IEEE Latin America Transactions*. vol. 17, Issue 4, pp. 684-697, 2019. DOI: 10.1109/TLA.2019.8891934
- [18] B. Li, C. Delpha, D. Diallo, A. Migan-Dubois. Application of Artificial Neural Networks to photovoltaic fault detection and diagnosis A review. *Renewable and Sustainable Energy Reviews*; vol. 138; 110512, 2021. DOI: 10.1016/j.rser.2020.110512.
- [19] M. Hussain, M. Dhimish, S. Titarenko, P. Mather. Artificial neural network based photovoltaic fault detection algorithm integrating two bi-directional input parameters. *Renewable Energy*. 155, 2020. DOI: 10.1016/j.renene.2020.04.023.
- [20] C. Colak, M. Yesilbudak, R. Bayindir. Forecasting of Daily Total Horizontal Solar Radiation Using Grey Wolf Optimizer and Multilayer Perceptron Algorithms. 8th International Conference on Renewable Energy Research and Applications (ICRERA), Brasov, Romania, pp. 939-942, 2019. DOI: 10.1109/ICRERA47325.2019.8997040.
- [21] J. M. Oliveira, D. S. Santos, R. M. Silva. Predição da radiação solar global usando modelos de redes neurais artificiais. vol. 4, no. 5, 2019. DOI: 10.21575/25254782rmetg2019vol4n5940.
- [22] A. Elsheikh, S. W. Sharshir, M. E. A. Elaziz, A. E. Kabeel. Modeling of solar energy systems using artificial neural network: A comprehensive review. *Solar Energy*. vol. 180, pp. 622-639, 2019. DOI: 10.1016/j.solener.2019.01.037.
- [23] S. Sobri, S. Koochi-Kamali, N. A. Rahim. Solar photovoltaic generation forecasting methods: A review. *Energy Conversion and Management*. vol. 156, pp. 459-497, 2018. DOI: 10.1016/j.enconman.2017.11.019.
- [24] F. Almonacid, E. F. Fernandez, A. Mellit, S. Kalogirou. Review of techniques based on artificial neural networks for the electrical characterization of concentrator photovoltaic technology. *Renewable and Sustainable Energy Reviews*. vol. 75, pp. 938-953, 2019. DOI: 10.1016/j.rser.2016.11.075.
- [25] H. A. Kazem, J. H. Yousif. Comparison of prediction methods of photovoltaic power system production using a measured dataset. *Energy Conversion and Management*. vol. 148, pp. 1070-1081, 2018. DOI: 10.1016/j.enconman.2017.06.058.
- [26] D. V. Fiorin, F. R. Martins, N. J. Schuch, E. B. Pereira. A utilização das redes neurais artificiais na previsão de radiação solar global. *Revista Brasileira de Ensino de Física*. vol. 33, no. 1, 2011. DOI: 10.1590/S1806-11172011000100009.
- [27] M. Vakili, S. Sabbagh-Yazdi, K. Kalhor, S. Khosrojerdi. Using Artificial Neural Networks for Prediction of Global Solar Radiation in Tehran Considering Particulate Matter Air Pollution. *Energy Procedia*. vol. 74, pp. 1205-1212, 2015. DOI: 10.1016/j.egypro.2015.07.764.
- [28] M. Benganem, A. Mellit. Radial Basis Function Network-based prediction of global solar radiation data: Application for sizing of a stand-alone photovoltaic system at Al-Madinah, Saudi Arabia. *Energy*. vol. 35, Issue 9, pp. 3751-3762, 2010. DOI: 10.1016/j.energy.2010.05.024.
- [29] A. Mellit, A. M. Pavan. A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy. *Solar Energy*. vol. 84, Issue 5, pp. 807-821, 2010. DOI: 10.1016/j.solener.2010.02.006
- [30] A. Mellit, S. A. Kalogirou, L. Hontoria, S. Shaari. Artificial intelligence techniques for sizing photovoltaic systems: A review. *Renewable and Sustainable Energy Reviews*. vol. 13, Issue 2, pp. 406-419, 2009. DOI: 10.1016/j.rser.2008.01.006
- [31] A. Mellit, M. Benganem, S. A. Kalogirou. Modeling and simulation of a stand-alone photovoltaic system using an adaptive artificial neural network: Proposition for a new sizing procedure. *Renewable Energy*. vol. 32, Issue 2, pp. 285-313, 2007. DOI: 10.1016/j.renene.2006.01.002
- [32] A. Mellit, M. Menghanem, M. Bendekhis. Artificial neural network model for prediction solar radiation data application for sizing stand-alone photovoltaic power system. *IEEE Power Engineering Society General Meeting*. vol. 1, pp. 40-44, 2005. DOI: 10.1109/PES.2005.1489526
- [33] A. S. S. Dorvlo, J. A. Jervase, A. Al-Lawati. Solar radiation estimation using artificial neural networks. vol. 71, Issue 4, pp. 307-319, 2012. DOI: 10.1016/S0306-2619(02)00016-8
- [34] A. P. Braga, A. P. de L. Carvalho, T. B. Ludermir. *Redes Neurais Artificiais: Teoria e Aplicações*. 2ª edição, Editora LTC, Rio de Janeiro. 2007.
- [35] D. S. Santos, J. M. Oliveira, R.M. Silva. Predição da Radiação Solar Global Usando Modelos de Redes Neurais Artificiais. *Revista Mundi Engenharia, Tecnologia e Gestão*. vol.4, Issue 5, pp. 191-204, 2019. DOI: 10.21575/25254782rmetg2019vol4n5940
- [36] Haykin, S. “Redes Neurais – Princípios e Prática”, 2ª ed., Bookman, 2001.
- [37] M. J. D Powell. Radial Basis Function Approximations to Polynomials. 12th Biennial Numerical Analysis Conference (Dundee). pp.223-241, 1987.
- [38] F. H. T. Vieira, R. P. Lemos, L. L. Ling. Aplicação de Redes Neurais RBF Treinadas com Algoritmo ROLS e Análise Wavelet na Predição de Tráfego em Redes Ethernet. VI Congresso Brasileiro de Redes Neurais, pp. 145-150, 2003. DOI: 10.21528/CBRN2003-034.
- [39] D. P. Lettenmaier, E. F. Wood. “Hydrologic Forecasting” in *Handbook of Hydrology*. Org. by Maidment, D. R., McGraw-Hill Inc., New York, USA, pp. 26.1–26.30, 1993.



**André Wagner de Barros Silva** Graduado em Eng. Elétrica pela UFC (2012), Pós-Graduado em Projeto, Execução e Controle em Eng. Elétrica pelo Instituto de Pós-Graduação (IPOG - 2015). Eng. Eletricista na UFCA e mestrando em Eng. Elétrica pela UFC.



**Breno Bezerra Freitas** Graduação em Eng. Elétrica pela UFC (2018), mestrando em Eng. Elétrica pela UFC e membro do Laboratório de Energias Alternativas (LEA) da UFC. Interesse em fotovoltaica, eficiência energética e modelagem 2D/3D.



**César Lédio de Alencar Filho** Graduado em Eng. Elétrica pela Unifor (2020). Mestrando em Eng. Elétrica pela UFC. Interesses: Planejamento Energético, Mercado de Energia, Inteligência Artificial.



**Claudivan Domingos de Freitas** Graduado em Eng. Elétrica pela UFC (2019). Mestrando em Eng. Elétrica pela UFC. Interesses: Proteção e Automação de SEP, Geração Distribuída, Redes Elétricas Inteligentes e Qualidade de Energia.



**Elder Alves de Sousa Junior** Técnico em eletrotécnica pelo IFCE (2013), graduação em Eng. Elétrica pelo Centro Universitário 7 de Setembro (UNI7) (2020), mestrando em Eng. Elétrica pela UFC, trabalha na INACE (Indústria Naval do Ceará).



**Erasmo Saraiva de Castro** Graduado em Eng. Elétrica pela UFC (2012) e Mestre em Eng. Elétrica pela UFC (2015). Doutorando em Eng. Elétrica pela UFC. Professor do curso de Engenharia Elétrica da UFC (campus Sobral). Interesses: Análise de Sistemas Elétricos de Potência, Eletrônica de Potência em Sistemas de Energia Elétrica, Geração Distribuída e Fontes Renováveis.



**Esdras Miranda de Araújo** Graduado em Eng. Elétrica pela UFPE (2003), Pós-Graduado em Gestão de Empresas pela Fundação Getúlio Vargas (2013). Mestrando em Eng. Elétrica pela UFC. Interesses: Geração distribuída, Comunidades Energéticas, *Smart grid*, Energia solar e Eficiência Energética.



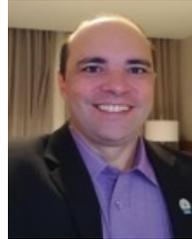
**Francisco Israel Freire Correia** Graduado em Eng. Elétrica pela UNIFOR (2018). Trabalha como Eng. Eletricista na empresa Clean Energy, empresa voltada para o ramo de energia solar. Interesses: Geração Fotovoltaica, Eficiência Energética e Sistema de Potência.



**Francisco Renato Ponte da Silva** Graduado em Eng. Elétrica pela UNIFOR (2019), cursando especialização em Eficiência Energética – UNIFOR. Proprietário de empresa voltada para instalações elétricas e eficiência energética, SATTVA ENERGIAS. Interesses: Geração fotovoltaica, Eficiência Energética e Laudos Elétricos.



**José Janiere Silva de Souza** Tecnólogo em Mecatrônica Industrial pelo IFCE (2017), Mestre em Eng. Elétrica pela UFC (2020). Professor efetivo do IFCE *Campus* Cedro. Interesses: Geração distribuída, Energia Solar e Veículos Elétricos.



**Luís L'Aiglon Pinto Martins** Graduado em Eng. Elétrica pela UFC (2000), MBA em Gestão de Projetos FGV (2009), Pós-graduado em Eng. de Manutenção pela UCAM (2013) e em Finanças pela PUCRS (2019). Mestrando em Eng. Elétrica pela UFC. Atua na manutenção de MPCCS da CHESF há 18 anos.



**Luis Rodolfo Rebouças Coutinho** Possui graduação em Eng. Elétrica pela UFC (2008) e Mestrado em Computação Aplicada pela UECE (2013). Atualmente, doutorando em Eng. Elétrica pela UFC, na área de Sistemas de Potência, e Professor do curso de Engenharia da Computação na UFC (*Campus* Quixadá). Possui interesse nas áreas de: sistemas embarcados, automação residencial, microgeração, modelagem computacional e teoria dos jogos.



**Natalia Pimentel Lado Ces** Graduação em Eng. Elétrica pela UFC (2018). Mestranda em Eng. Elétrica pela UFC. Linha de pesquisa: Energias Renováveis e Sistemas Elétricos, com ênfase em Microrredes



**Ricardo Castelo** Graduação em Eng. Elétrica - UNIFOR, Especialização em Geração Solar Fotovoltaica – SENAI-GTZ, Especialização em Geração Termossolar – ISITEC-GTZ, Especialização em Geração de Energia Eólica – Garrah Hassan/GTZ, MBA em Gerenciamento de Projetos – Mrh / FGV-RJ, MBA em Gestão Estratégica de Negócios – Mrh / FGV-RJ, Especialização em Eng. e Segurança do trabalho – FAAP, Especialização em Gerenciamento de Meio Ambiental – USP.



**Paulo Cesar Marques de Carvalho** Graduação em Eng. Elétrica pela UFC (1989), mestrado em Eng. Elétrica pela UFPB (1992) e doutorado em Eng. Elétrica pela Universidade de Paderborn, Alemanha (1997). Professor titular do DEE - UFC. Coordena o Laboratório de Energias Alternativas da UFC. Bolsista de produtividade em pesquisa do CNPq.



**Tatiane Carlyne Carneiro** Graduação em Eng. Ambiental pela UFCG (2012) e Mestrado em Eng. Elétrica pela UFC (2014). Atualmente é professora assistente do Departamento de Eng. Ambiental da UFMA e doutoranda do Programa de Pós-Graduação em Eng. Elétrica da UFC.