



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA

MAGNO CESAR FERNANDES BRAGA

PREVISÃO DE GERAÇÃO FOTOVOLTAICA UTILIZANDO O MÉTODO *CASCADE*
***FORWARD BACK PROPAGATION* DE REDES NEURAS ARTIFICIAIS**

FORTALEZA

2022

MAGNO CESAR FERNANDES BRAGA

PREVISÃO DE GERAÇÃO FOTOVOLTAICA UTILIZANDO O MÉTODO *CASCADE*
FORWARD BACK PROPAGATION DE REDES NEURAS ARTIFICIAIS

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia Elétrica.

Orientador: Prof. Dr. Paulo Cesar Marques de Carvalho

Coorientadora: Prof. M.Sc. Tatiane Carolyne Carneiro

FORTALEZA

2022

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

B794p Braga, Magno Cesar Fernandes.
Previsão de geração fotovoltaica utilizando o método Cascade Forward Back Propagation de redes neurais artificiais / Magno Cesar Fernandes Braga. – 2022.
55 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia, Curso de Engenharia Elétrica, Fortaleza, 2022.

Orientação: Prof. Dr. Paulo Cesar Marques de Carvalho.
Coorientação: Profa. Dra. Tatiane Carlyne Carneiro.

1. Redes neurais artificiais. 2. Redes Cascade Forward Back Propagation. 3. Sistemas fotovoltaicos. 4. Previsão de geração fotovoltaica. I. Título.

CDD 621.3

MAGNO CESAR FERNANDES BRAGA

PREVISÃO DE GERAÇÃO FOTOVOLTAICA UTILIZANDO O MÉTODO *CASCADE*
FORWARD BACK PROPAGATION DE REDES NEURAS ARTIFICIAIS

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia Elétrica.

Aprovada em: 18 de Fevereiro de 2022

BANCA EXAMINADORA

Prof. Dr. Paulo Cesar Marques de
Carvalho (Orientador)
Universidade Federal do Ceará (UFC)

Prof. M.Sc. Tatiane Carolyne
Carneiro (Coorientadora)
Universidade Federal do Maranhão (UFMA)

Prof. Dr. Arthur Plínio de Souza Braga
Universidade Federal do Ceará (UFC)

Eng. André Abreu de Melo Lima
Universidade Federal do Ceará (UFC)

*Aos meus pais Magno e Kátia, a minha família
e aos amigos.*

AGRADECIMENTOS

Primeiramente a Deus, pois sem a intercessão dele nada seria possível. Aos meus pais, Magno Braga e Kátia Fernandes que sempre me apoiaram e através do exemplo me incentivaram a se tornar uma pessoa melhor, e meu pai que foi fonte de inspiração e de profissionalismo na carreira a ser seguida. Agradeço também aos meus irmãos, Emanuelle Braga e João Braga por tantos momentos compartilhados e companheirismo e a minha namorada Letícia Caetano por estar sempre presente, me apoiando e me inspirando a crescer como pessoa.

Ao Professor Dr. Paulo Cesar Marques de Carvalho e Professora M.Sc. Tatiane Carlyne Carneiro, pela oportunidade e orientação nesse trabalho. Aos membros da banca pelas diversas sugestões em prol da melhoria desse trabalho. E a todos os professores do Departamento de Engenharia Elétrica da Universidade Federal do Ceará.

A Tecsys Jr. por ter sido minha porta de entrada no mercado de trabalho. E aos amigos que fiz por lá, em especial, Wandick Landry, Cláudio César, Regis Rolim e Jadir Júnior.

A Enpecel Energia Solar por acreditar no meu trabalho e aos companheiros de trabalho que se tornaram amigos, Wandick Landry, Lucas Bitu e Jakson Santana.

Aos meus amigos que me acompanham desde o início da graduação, Claudivan Freitas, Filipe Viana, Artur Nogueira, Felipe Monteiro, Luis Eduardo, Lucas Allan, Yan Matias, Philippe Romão e em especial ao amigo André Abreu que me acompanha desde o ensino médio, pelos bons momentos, risos e noites em claro estudando.

“A persistência é o caminho do êxito.”

(Charles Chaplin)

RESUMO

O trabalho apresenta o estudo de uma Rede Neural Artificial (RNA) do tipo *Cascade Forward Back Propagation* (CFBP) aplicada para a realização de previsões da potência de saída do inversor de um sistema fotovoltaico (FV) em um horizonte de 1 hora. O intuito da pesquisa foi a aplicação de um modelo capaz de realizar previsões assertivas e confiáveis, tendo em vista o cenário de crescimento da utilização da fonte FV que possui alto nível de intermitência em seu nível de produção, tornando-se esse tipo de informação essencial para uma boa gestão do sistema de energia e para o próprio crescimento dessa fonte energética na matriz elétrica do país. A RNA proposta tem como características: arquitetura CFBP, a qual a quantidade de entradas, camadas internas, neurônios ocultos e taxa de aprendizagem foram ajustados de acordo com o tipo de dados que foram fornecidos para treinamento e validação da rede, o mecanismo de aprendizado aplicado foi o algoritmo de *backpropagation* e função de ativação sigmóide. O treinamento e validação do método foi realizado com a utilização de dados da potência de saída de um sistema FV residencial, os quais foram coletados através da plataforma de monitoramento do inversor e tratados para a implementação das redes. Para efeito de comparação da assertividade do modelo analisado, aplicou-se uma RNA do tipo *Multi-Layer Perceptron* (MLP) que também teve a sua performance analisada. Os dois modelos foram aplicados em dois cenários distintos em relação ao tratamento dos dados utilizados, o primeiro considerando as 24 horas do dia e o segundo com a amostra apenas do período em que o sistema encontrava-se em funcionamento. Foram implementadas ao final do trabalho métricas para a análise do erro apresentado pelos modelos. A arquitetura CFBP implementada para o cenário de dados sem os zeros, por exemplo, obteve os seguintes resultados: *Root Mean Square Error* (RMSE)= 54,14 W, $R^2= 99,97\%$ e *Mean Absolute Error* (MAE)= 43,41 W, tornando-se a RNA com o melhor desempenho apresentado no estudo.

Palavras-chave: Redes Neurais Artificiais. Redes *Cascade Forward Back Propagation*. Sistemas Fotovoltaicos. Previsão de geração Fotovoltaica

ABSTRACT

The work presents the study of a Artificial Neural Network (ANN) called CFBP applied for the implementation of predicting 1 hour ahead output power of PhotoVoltaic (PV) system. The intention of the research was the implementation of a model capable of improve reliable forecasts due to the growing scenario of PV source, that presents high flashing in the production level, making this kind of information essential for a great management of the energy system and for growth of this source in the country's electric matrix. The proposed RNA features: CFBP architecture, which number of inputs, hidden layers, neurons and learning rate were adjusted according to the data provided for ANN's training and validation, the learning mechanism applied is backpropagation and the sigmoid activation function. The training and validation method applied is accomplished using the output power data from a residential PV plant, which were collected through the monitoring system of the PV inverter and sized for the ANN implementation. For the purpose of comparing the accuracy of the applied model, an MLP ANN was implemented and had its performance analyzed. The both models have been applied in two distinct conditions in relation to the processing of data, the fist considering the 24 hours a day and the second considering only the system PV operation time course. Metrics were implemented at the end of the work to analyze the error presented by the models. The CFBP architecture implemented for the data scenario without the zeros, for example, obtained the following results: RMSE= 54.14 W, $R^2= 99.97\%$ and MAE= 43.41 W, becoming the ANN with the best performance presented in the study.

Palavras-chave: *Artificial Neural Network. Cascade Forward Back Propagation network. PhotoVoltaic system. PhotoVoltaic generation forecast*

LISTA DE FIGURAS

Figura 1 – Matriz Elétrica Brasileira	15
Figura 2 – Evolução da Geração FV no Brasil	18
Figura 3 – Modelo de McCulloch-Pitts	22
Figura 4 – Modelo de Neurônio Geral	23
Figura 5 – Modelo de Rede Direta	24
Figura 6 – Modelo de Rede com Ciclos	25
Figura 7 – Fases de treinamento do <i>backpropagation</i>	28
Figura 8 – Função de ativação sigmóide	29
Figura 9 – Modelo de Rede Perceptron	30
Figura 10 – Fronteira de Separação	32
Figura 11 – Modelo de Rede <i>Perceptron</i> multicamadas	32
Figura 12 – Modelo de Rede CFBP	33
Figura 13 – Amostras típicas das sete classes de nuvem	38
Figura 14 – Arquitetura CFBP desenvolvida	41
Figura 15 – Alocação dos módulos da planta FV	43
Figura 16 – Monitoramento da Potência de saída do inversor	44
Figura 17 – Arquitetura CFBP dados completos	46
Figura 18 – Arquitetura CFBP dados sem zeros	46
Figura 19 – Arquitetura MLP dados completos	47
Figura 20 – Arquitetura MLP dados sem zeros	47
Figura 21 – Resultados CFBP para dados completos	50
Figura 22 – Resultados CFBP para dados sem os zeros	50
Figura 23 – Resultados MLP para dados completos	51
Figura 24 – Resultados MLP para dados sem os zeros	51

LISTA DE TABELAS

Tabela 1 – Especificações da planta FV	44
Tabela 2 – Resultado das métricas de erro aplicadas	52

LISTA DE ABREVIATURAS E SIGLAS

AnEn	<i>Analog Ensemble</i>
ANN	Artificial Neural Network
AZ	Azimuth
CFBP	<i>Cascade Forward Back Propagation</i>
CN	Percentual de Cobertura de Nuvens
D-PNN	<i>Differential Polynomial Neural Network</i>
EL	Elevação
ELM	<i>Extreme Learning Machine</i>
FTEP	Fornecimento Total de Energia Primária
FV	fotovoltaico
GD	Geração Distribuída
IHG	Irradiância Horizontal Global
MAE	<i>Mean Absolute Error</i>
MLP	<i>Multi-Layer Perceptron</i>
NARX	<i>non-linear auto-regressive network with exogenous input</i>
NWP	<i>Numerical Weather Prediction</i>
PDE	<i>Partial Differential Equation</i>
PM	Potência Medida
PV	PhotoVoltaic
R2	Erro Quadrático
RAMS	<i>Regional Atmospheric Modeling System</i>
RMSE	<i>Root Mean Square Error</i>
RNA	Rede Neural Artificial
RNN	Redes Neurais Naturais
RVFL	<i>Random Vector Functional Link</i>
SARIMA	<i>Seasonal Autoregressive Integrated Moving Average</i>
SLFNs	<i>single-hidden layer feedforward neural networks</i>
SVR	<i>support vector regression</i>
T2M	Temperatura a dois metros acima da superfície
UE	União Europeia

LISTA DE SÍMBOLOS

CO_2 Dióxido de carbono

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Geração Fotovoltaica no Brasil e no Mundo	14
1.2	Previsibilidade de Geração Fotovoltaica	18
2	REDES NEURAIIS ARTIFICIAIS	21
2.1	Introdução às Redes Neurais Artificiais	21
2.2	Modelos de Neurônios	22
2.3	Topologia das Redes	24
2.4	Aprendizado	25
2.5	Redes Neurais Artificiais Consideradas	30
2.5.1	<i>Rede Perceptron</i>	30
2.5.2	<i>Redes Perceptron Multicamadas</i>	32
2.5.3	<i>Redes CFBP</i>	33
2.6	Conclusão	34
3	ESTADO DA ARTE DA UTILIZAÇÃO DE REDES NEURAIIS ARTIFICIAIS PARA PREVISÃO SOLAR	35
3.1	Metodologia Baseada em Rede Neural Artificial e Conjunto Analógico	35
3.2	Metodologia Baseada em Máquina de Extremo Aprendizado	36
3.3	Metodologia Baseada em Informações de <i>Sky-Imager</i> e Redes Neurais	37
3.4	Metodologia Baseada em Cálculo Operacional	38
3.5	Metodologia Baseada em um Modelo Híbrido Assistido pela Decomposição de Wavelet	39
3.6	Metodologia Baseada em Redes Neurais Artificiais CFBP	40
3.7	Conclusão	42
4	METODOLOGIA PROPOSTA	43
4.1	Descrição da Planta FV e Conjunto de Dados	43
4.2	Aplicação da RNA	45
5	RESULTADOS E DISCUSSÕES	49
6	CONCLUSÕES	53
	REFERÊNCIAS	55

1 INTRODUÇÃO

A compreensão da mudança da matriz elétrica global torna-se essencial para o entendimento do contexto em que o estudo está inserido, por meio das demandas e necessidades vivenciadas pela sociedade. Dessa forma, iniciamos o estudo relatando acerca do crescimento na utilização da fonte FV, seus benefícios, impactos e características na Seção 1.1 e além disso, a importância da obtenção de modelos acertivos para a previsão de geração FV para o operador do sistema elétrico na Seção 1.2.

1.1 Geração Fotovoltaica no Brasil e no Mundo

Economias em desenvolvimento enfrentam um grande desafio que consiste em um acelerado aumento no consumo elétrico ao mesmo tempo que o impacto gerado pela utilização de recursos não renováveis deve ser reduzido. De acordo com Garlet *et al.* (2020), existe um grande incentivo para o rápido desenvolvimento de novas fontes de energia através de políticas que seguem o amadurecimento das tecnologias de geração de energia renovável.


Nesse contexto, a geração FV tem ganhado destaque nos últimos anos, sendo considerada como um dos mercados mais promissores no campo de energias renováveis para a redução das desvantagens da queima de combustíveis fósseis na produção de energia elétrica. Geração FV é considerada uma fonte limpa de energia, livre de ruídos e que vem se tornando uma das principais fontes renováveis em mercados de grande importância. A expansão do uso dessa fonte de energia ao redor do mundo tem ocorrido em decorrência do crescimento da competitividade do setor de geração FV em relação aos demais recursos energéticos combinado com o aumento da demanda por eletricidade e com a necessidade de redução da poluição ambiental, diminuindo as emissões de dióxido de carbono e fornecendo o acesso a energia para aqueles que não possuem distribuição local de energia por meio de concessionárias convencionais, segundo David *et al.* (2021).

Em se tratando de Brasil, podemos dizer que o país possui uma matriz elétrica limpa, principalmente em decorrência da intensiva utilização de recursos hídricos para a geração de energia elétrica. De acordo com ABSOLAR, Associação Brasileira de Energia Solar Fotovoltaica (2021) a matriz elétrica brasileira possui a potência total de 176.225 MW, dos quais 59,3% são referentes ao recurso hídrico. A Figura 1 demonstra a composição da matriz elétrica brasileira. Dessa forma, podemos observar uma grande dependência do país em relação ao

nível de disponibilidade de água em seus reservatórios destinados à geração de energia elétrica, tornando a operação do sistema muito sensível aos períodos de seca que podem resultar em racionamento de energia.

O desenvolvimento do uso da energia solar no Brasil surge como uma alternativa para a diversificação da matriz elétrica no país, além disso, de acordo com David *et al.* (2021) barreiras e problemas enfrentados pelo setor de energia brasileiro também incentivam o crescimento dessa fonte renovável de energia. As condições naturais do território nacional são favoráveis para a difusão desse mercado, como o alto nível de insolação e grandes reservas de quartzo de qualidade, que pode gerar grande vantagem competitiva na produção de silício de alta pureza utilizado na fabricação de células e módulos solares, segundo Jr *et al.* (2017). Porém, devemos entender que esse desenvolvimento é afetado diretamente por uma série de fatores com alto grau de incertezas, como o segmento político, social, econômico e ambiental, e além disso, torna-se importante analisar os impactos que o crescimento da Geração Distribuída (GD) pode acarretar ao sistema de energia elétrica e à sociedade.

Figura 1 – Matriz Elétrica Brasileira



Fonte: ABSOLAR, Associação Brasileira de Energia Solar Fotovoltaica (2021)

De acordo com Ferreira *et al.* (2018), os sistemas FV, principalmente aqueles conectados ao sistema de distribuição local, oferecem vários benefícios ao sistema elétrico, como a redução de perdas pela transmissão e distribuição de energia, a redução do investimento necessário nas linhas de transmissão e distribuição e contribuem com o aumento do volume de eletricidade disponível durante os horários de pico de demanda. Essas vantagens tornam-se ainda mais evidentes no estudo realizado por Lacchini e Santos (2013), que comparou a geração FV com a geração através de termelétricas. Em decorrência desse tipo de fonte se localizar próximo às minas de carvão, por questões operacionais, apresentam geralmente grandes distâncias dos centros de consumo e conseqüentemente necessitam de alto investimento em linhas de transmissão, que intrinsecamente apresentarão perdas de energia.

Assim, a geração FV não implica apenas em vantagens na esfera ambiental, apesar de ser um aspecto de grande importância, mas pode proporcionar benefícios econômicos de forma direta e indireta, além de tornar o sistema elétrico local mais eficiente em se tratando de perdas e de disponibilidade energética. De acordo com Garlet *et al.* (2020), países que possuem políticas de desenvolvimento sustentável utilizam a tecnologia FV como uma fonte renovável competitiva, incluindo em áreas com o acesso limitado ou sem energia elétrica. A possibilidade de desenvolvimento de indústrias de alta tecnologia para suprir a demanda desse mercado em ascensão fornece impacto social com a geração de empregos de forma direta e indireta.


Os problemas relacionados com a difusão da GD FV e com o crescimento da competitividade do mercado não estão concentrados em uma única esfera e apresentam uma natureza complexa. A disponibilidade do recurso solar é um fator ambiental que influencia diretamente na viabilidade de construção de plantas de energia solar, pois altera o tempo de retorno do investimento, localidades com maior recurso solar normalmente apresentam maior potencial para a difusão dessa fonte de energia. A performance econômica de sistemas FV está relacionada com a tecnologia solar que está sendo empregada no projeto, o custo dos componentes e a política tarifária aplicada na localidade. Assim, políticas governamentais que incentivem o desenvolvimento do setor são essenciais para o crescimento do mesmo, sejam elas de ordem tarifária, na isenção de impostos sobre os componentes do sistema FV ou até mesmo na definição de um padrão de compensação mais atrativo para quem possuir GD. De acordo com David *et al.* (2021), o Brasil possui potencial para o desenvolvimento de toda a cadeia de produção de sistemas FV através de políticas governamentais, iniciativas técnico-econômicas e abertura e desempenho competitivo do mercado.

O uso de plantas FV conectadas à rede elétrica foi incentivado pela primeira vez no Brasil através da regulamentação pela Resolução Normativa nº 482/2012 da ANEEL, que estabeleceu as condições gerais para o acesso à micro e mini GD ao sistema de distribuição de energia e definiu o modelo do sistema de compensação de energia aplicado no país. De acordo com a Resolução, o consumidor pode gerar a sua energia através de diferentes fontes e fornecer o excedente à rede da concessionária local. Essa energia ativa injetada na rede fará a composição de um banco de créditos de energia que deve ser utilizado para o abatimento do consumo do cliente. Nesse formato, a energia fornecida ao consumidor nos períodos de sol advém do próprio sistema de energia solar (autoconsumo) enquanto o excedente gerado é injetado na rede, no período noturno o consumo é suprido pela concessionária e ao final de cada mês o consumo total é abatido pelo que foi injetado durante o período. É importante ressaltar que os créditos devem ser utilizados apenas para a compensação do consumo de energia, não existindo nenhum tipo de pagamento pela energia injetada na rede de distribuição. De acordo com Jr *et al.* (2017), esse incentivo não é forte o suficiente para impulsionar a GD FV e reflete o fato de que as concessionárias de distribuição não estão preparadas para receber grandes quantidades de geração, fazendo-se necessário a realização de reforços nos investimentos em tecnologias de controle e proteção da rede.

Apesar disso, a geração FV no Brasil vem apresentando grande evolução nos últimos anos e possui uma tendência de crescimento da sua parcela de contribuição na matriz elétrica do país. A Figura 2 ilustra essa evolução. Podemos observar que grande parte da expansão do setor de geração FV se deve à disseminação da GD no país. Esse crescimento acelerado ocorreu em decorrência de uma série de fatores que incentivaram a adesão de sistemas FV por clientes do segmento comercial e residencial, entre esses fatores podemos destacar:

- Melhora nas políticas públicas (Resoluções Normativas/incentivos fiscais);
- Queda dos preços dos equipamentos (inversores/módulos FV);
- Avanços na tecnologia FV (melhoria na eficiência dos sistemas);
- Alto valor de tarifa energética aplicada (crise hídrica vivenciada pelo país);
- Linhas de financiamento próprias para energia solar com valores de juros acessíveis;
- Alto grau de competitividade entre as empresas do segmento.

Figura 2 – Evolução da Geração FV no Brasil



Fonte: ABSOLAR, Associação Brasileira de Energia Solar Fotovoltaica (2021)

1.2 Previsibilidade de Geração Fotovoltaica

Com o importante crescimento da utilização de fontes renováveis de energia no mundo e no Brasil, torna-se cada vez mais eminente a obtenção de uma boa precisão na previsão de geração de tais fontes de energia, principalmente para as energias solar e eólica, as quais apresentam alta intermitência em seus níveis de produção. De acordo com Domingos *et al.* (2020), este avanço possibilitaria o aumento do uso das fontes renováveis de energia, permitindo, por exemplo, sua inclusão no sistema de despacho pelo operador do sistema elétrico. Assim, o potencial de inserção da energia solar na matriz energética global necessita de uma adequada gestão de fornecimento de energia pelo órgão de controle, que através de uma previsão confiável da irradiação solar futura na região permitiria ao operador da rede elétrica avaliar em que momentos serão necessárias complementações do abastecimento com outras fontes, segundo Marinho *et al.* (2020). Além disso, a obtenção de uma estimativa da produção anual de energia é uma etapa fundamental para as análises de viabilidade de um empreendimento de energia solar, como mostra o estudo realizado por Silva *et al.* (2020), reforçando que a estimativa de geração é uma ferramenta aliada na busca por uma maior penetração das energias renováveis no sistema

elétrico.

Como dito anteriormente, um dos principais obstáculos da aplicação dessa tecnologia é que a sua geração é variável ao longo do tempo, ou seja, é totalmente dependente das condições climáticas e da nebulosidade da região. De acordo com Domingos *et al.* (2020), essa condição ocorre principalmente em climas tropicais, que apesar de apresentarem altos índices de radiação solar, possuem também altos níveis de nebulosidade, podendo ocasionar flutuações na tensão gerada e também na frequência da rede.

Dessa forma, para assegurar a estabilidade do sistema elétrico e a segurança do suprimento energético apresenta-se como principal solução o desenvolvimento dos métodos de previsão da geração FV. De acordo com Yang *et al.* (2018), o domínio da previsão da intermitência solar e eólica representa o maior desafio para a mudança da base de combustíveis fósseis na produção de energia para uma base 100% de fontes renováveis de energia.

As usinas termelétricas e hidrelétricas são utilizadas para absorver as flutuações de energia elétrica. Para compensar a variabilidade e pouca previsibilidade de fontes renováveis de energia como a solar e eólica, as termelétricas necessitam estar em modo de espera em uma operação sem carga, resultando em largas perdas econômicas para as empresas. Uma boa previsão da radiação solar para sistemas FV pode reduzir esse modo de espera, segundo Inage (2017). Além disso, uma estimativa correta poupa gastos desnecessários com combustíveis, evita emergência na compra de energia e é útil para a manutenção, armazenamento de energia e sua comercialização, segundo Domingos *et al.* (2020). Problemas relacionados à flutuação de tensão, qualidade de energia e estabilidade da rede elétrica também podem se beneficiar de estimativas bem elaboradas.

De acordo com Marinho *et al.* (2020), o operador da rede precisa de previsões confiáveis em diferentes horizontes de tempo, cada uma com a sua aplicabilidade. No artigo desenvolvido por Domingos *et al.* (2020) é destacado cada um desses horizontes de previsão e a sua respectiva utilidade para o operador do sistema elétrico, como é demonstrado a seguir:

- Previsões de muito curto prazo (De poucos segundos até minutos): São importantes para a suavização de energia, despacho de eletricidade em tempo real e reservas ideais;
- Previsões de curto prazo (De uma hora a sete dias): Importante na programação e despacho de energia elétrica e para projetar a gestão de um sistema de energia;
- Previsões de médio prazo (De uma semana até um mês): Importante para o

planejamento do sistema de energia e do cronograma de manutenção, além do entendimento da disponibilidade de energia elétrica no futuro;

- Previsões de longo prazo (De um mês até um ano): Útil para o planejamento de geração, transmissão e distribuição de energia e sua operação de segurança;

Nesse contexto, a utilização de métodos de previsão numérica de tempo, do inglês *Numerical Weather Prediction* (NWP), análise de séries temporais, aplicações envolvendo o processamento de imagens, utilização de algoritmos de aprendizagem de máquina, destacam-se como abordagens comumente aplicadas para a obtenção de previsões de irradiação solar e de geração FV, segundo Bassetto *et al.* (2020).

Neste trabalho foi adotada a metodologia de previsão de geração através do desenvolvimento de uma RNA. A RNA a ser utilizada trata-se de uma rede CFBP, que consiste em um modelo modificado de uma rede MLP, classificada como uma rede do tipo *feedforward* e que realiza o seu treinamento por meio do processo de *backpropagation*.

De acordo com Bassetto *et al.* (2020), esse tipo de técnica apresenta a habilidade em aprender a partir de informações conhecidas e desejadas, não conhecendo o comportamento matemático dos dados, com a possibilidade de interpretar informações falsas sem alterar os resultados. Além disto, pode estimar resultados a partir de conhecimentos prévios de variáveis e grandezas físicas diferentes e ajustar os valores das variáveis de processamento de acordo com o valor desejado. Dessa forma, esse tipo de modelo é muito utilizado para reconhecimento, classificação de padrões, agrupamento, previsão e nos últimos anos na estimativa de variáveis astronômicas.

Dessa forma, o presente Trabalho de Conclusão de Curso (TCC) tem como objetivo a aplicação de uma RNA do tipo CFBP para a previsão da potência de uma planta FV conectada à rede e instalada em um telhado residencial na cidade de Fortaleza, Ceará. O restante do trabalho está organizado da seguinte forma: Capítulo 2 descreve acerca do desenvolvimento e funcionamento dos modelos de RNA considerados, introduzindo os tópicos essenciais para entendimento do tema; Capítulo 3 foca em relatar estudos desenvolvidos na área de previsão FV utilizados como referência para o trabalho em questão; Capítulo 4 descreve a metodologia aplicada para o trabalho, incluindo a descrição da planta FV utilizada, método de coleta dos dados e explicação da metodologia proposta; Capítulo 5 discorre acerca dos resultados da simulação e discussão dos mesmos; Capítulo 6 fornece a conclusão do trabalho.

2 REDES NEURAIIS ARTIFICIAIS

O detalhamento dos princípios de funcionamentos das RNA são importantes para o completo entendimento dos modelos aplicados neste estudo. Assim no capítulo em que se segue são apresentados conceitos introdutórios acerca de RNA. Na Seção 2.1 definimos RNA, na Seção 2.2 apresentamos o conceito e funcionamento do neurônio artificial, na Seção 2.3 são demonstrados os principais tipos de topologias de redes, na Seção 2.4 os tipos de aprendizado e na Seção 2.5 a estruturação do modelo de RNA do tipo CFBP.

2.1 Introdução às Redes Neurais Artificiais

O desenvolvimento de pesquisas na área de RNA teve como sua principal motivação o reconhecimento da grande capacidade de processamento de dados apresentado pelo cérebro humano. De acordo com Haykin (2007), o cérebro é um computador altamente complexo, não-linear e paralelo que possui a capacidade de organizar os seus constituintes estruturais, conhecidos como neurônios, de forma a realizar certos processamentos muito mais rapidamente que o mais rápido computador digital hoje existente. Dessa forma, buscou-se a construção de modelos artificiais capazes de simular o comportamento da estrutura cerebral e desempenhar funções de forma semelhante, como reconhecimento de padrões, percepção, controle motor e até mesmo a capacidade de desenvolver aprendizado.

Nesse contexto, utilizaremos a definição de RNA apresentada por Haykin (2007): Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torna-lo disponível para uso. Ela se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;
2. Forças de conexões entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido;

É importante destacarmos que o processo de aprendizagem é aplicado através da modificação dos pesos sinápticos, que representam as conexões entre os neurônios da rede e existem diversas formas de realizar esse procedimento.

Assim, podemos sintetizar uma RNA como um processador de dados que busca modelar os circuitos cerebrais e dessa forma apresentar um comportamento inteligente, através

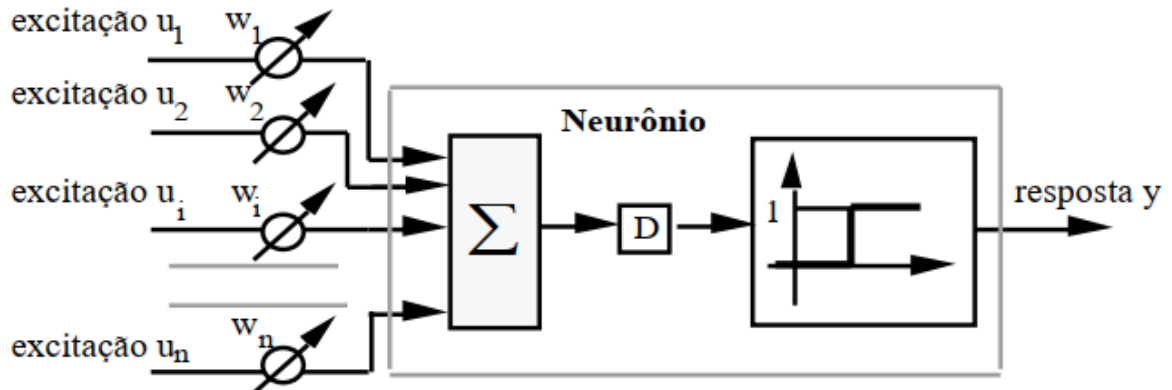
do processo de aprendizagem, tornando-se capaz de resolver problemas complexos.

2.2 Modelos de Neurônios

O estudo de RNA está intrinsecamente relacionado aos modelos de neurônios artificiais desenvolvidos, pois trata-se da composição das RNA. Dessa forma, a apresentação desses modelos torna-se importante no trabalho em questão. Como dito anteriormente, a construção de RNA possui inspiração nos neurônios biológicos, por meio de uma simplificação de seus componentes e funcionamento. Contudo, devemos compreender que as RNA ainda estão muito distantes das Redes Neurais Naturais (RNN) e as semelhanças apresentadas são mínimas na maioria das vezes.

O primeiro modelo de neurônio foi proposto por McCulloch e Pitts em 1943, interpretando o funcionamento do neurônio como um circuito binário, como mostra a Figura 3.

Figura 3 – Modelo de McCulloch-Pitts



Fonte: Barreto (2002)

As entradas apresentadas na Figura 3 são combinadas por uma soma ponderada, produzindo a entrada efetiva do neurônio.


$$entrada_e = \sum_{i=1}^n w_i u_i \quad (2.1)$$

Dessa forma, o neurônio de McCulloch-Pitts permite que os estímulos fornecidos apresentem níveis diferentes de excitação entre eles, ou seja, algumas entradas exercerão maior influência na resposta do neurônio do que outras, assim como ocorre no neurônio biológico. Assim, o peso sináptico determina a relevância de cada uma das entradas, tornando-se elemento de extrema importância para o funcionamento e ajuste da RNA.

Por meio da equação 2.1, denominada função de combinação, o neurônio totaliza todas as entradas e os seus respectivos pesos. Esse resultado parcial deve ser comparado com um parâmetro denominado *threshold*, com isso o neurônio só fornecerá a sua resposta quando a soma dos impulsos recebidos ultrapassar o seu limiar de excitação, caso contrário trata-se de um potencial inibitório. Fazendo a diferença entre a entrada fornecida ao neurônio matemático e o seu limiar de excitação obtemos o argumento da função de transferência, que irá fornecer a saída do neurônio, restringindo as possíveis respostas em um determinado intervalo de valores.

Utilizando o modelo de McCulloch e Pitts como referência foi desenvolvido o modelo geral do neurônio, que pode ser tratado como uma generalização do modelo apresentado anteriormente. De forma similar, o modelo geral combina as entradas através de uma função (ϕ), geralmente a soma ponderada dos valores, que produzirá o estado de ativação do neurônio e por meio de uma função de transferência (η) fornece a saída. O threshold (θ) também se faz presente no modelo generalista. Esse modelo matemático de neurônio também pode incluir uma polarização, denominada bias de entrada. Aplicada a função de combinação essa variável possibilita uma maior capacidade de aproximação da RNA. O valor do bias é ajustado da mesma forma que os pesos sinápticos. A utilização do bias permite que o neurônio apresente uma saída não nula mesmo que todas as entradas sejam nulas. A Figura 4 demonstra o modelo geral de neurônio.

Figura 4 – Modelo de Neurônio Geral



Fonte: Barreto (2002)

Partindo da concepção descrita do neurônio matemático, várias arquiteturas e modelos de RNA surgiram aplicando-se diferentes técnicas e combinações entre esses neurônios, propiciando a criação de redes especializadas para cada tipo de aplicabilidade.


2.3 Topologia das Redes

De acordo com Barreto (2002), podemos caracterizar uma RNA como um sistema composto por vários neurônios interligados entre si através de conexões sinápticas. Nesse contexto, torna-se comum a representação das RNA em camadas, onde os neurônios que recebem os sinais de excitação pertencem a camada de entrada da rede, neurônios que possuem sua saída como a resposta final da rede pertencem a camada de saída e os neurônios que não pertencem à camada de entrada ou de saída são denominados neurônios internos e podem se organizar em uma ou mais camadas internas da rede.

A maneira pela qual os neurônios estruturam-se entre si irá determinar a topologia da RNA. Essa organização apresentada é de grande importância, pois irá refletir diretamente no algoritmo de aprendizagem utilizado para treinar a rede. Iremos definir a seguir as duas principais arquiteturas de redes aplicadas no estudo de RNA.

As Redes Diretas ou Redes Alimentadas Adiante, do inglês *Feedforward*, são estritamente do tipo alimentada adiante ou cujo o grafo não possui ciclos. Assim, os neurônios em cada camada da rede têm como suas entradas apenas os sinais de saída da camada precedente. A grande popularidade desse tipo de rede se justifica pela existência de métodos de aprendizagem bastante difundidos e de baixa complexidade de aplicação. A Figura 5 exemplifica um modelo para uma rede *feedforward*.

Figura 5 – Modelo de Rede Direta




Fonte: Silva *et al.* (2010)

O segundo modelo estrutural trata-se das Redes com Ciclos ou Redes Recorrentes, que se caracterizam por apresentar pelo menos um laço de realimentação, ou seja, o grafo de conectividade entre os neurônios possuem, ao menos, um ciclo. Esse fato apresenta um impacto significativo na capacidade de aprendizagem desse tipo de rede e no seu desempenho. Um modelo de rede recorrente é demonstrado na Figura 6.

Em resumo, as redes recorrentes se diferenciam das redes *feedforward* pela utilização de loops de *feedback* em seus neurônios, tornando-se as entradas uma composição de novos estímulos com as saídas fornecidas anteriormente. Por esse motivo, costuma-se dizer que as redes recorrentes possuem memória, pois elas se utilizam da sequência de informações fornecidas pela própria rede. Essa informação sequencial é preservada no estado oculto da rede recorrente. Entretanto, como veremos no decorrer do trabalho, a topologia de rede adotada no estudo em questão foi o modelo de rede direta em decorrência da utilização do algoritmo de *backpropagation* para o treinamento das RNA.

Figura 6 – Modelo de Rede com Ciclos



Fonte: Silva *et al.* (2010)

2.4 Aprendizado

A capacidade de aprender é uma propriedade essencial para uma RNA, esse processo é realizado através das interações da rede com o seu ambiente e por meio da aprendizagem busca-se o aprimoramento do desempenho apresentado. Uma RNA aprende acerca do seu

ambiente através de um processo interativo de ajustes aplicados a seus pesos sinápticos e níveis de bias. De uma forma ideal, após cada interação do processo de aprendizagem a rede se torna mais instruída acerca do ambiente em que está inserida. De acordo com Haykin (2007) podemos definir o conceito de aprendizagem no contexto de redes neurais como: aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre.

Assim, podemos perceber que existem diversas formas de se implementar o processo de aprendizagem em RNA, em que cada método apresentará vantagens específicas. De forma resumida, os algoritmos de aprendizagem se diferem pela forma como é formulado o ajuste de um peso sináptico de um neurônio.

De acordo com NUNES e SILVA (2018) um dos recursos mais relevantes de uma RNA é a capacidade de aprendizado através da apresentação de amostras de dados que representam o comportamento de um determinado sistema. Após a rede ter aprendido a relação entre entradas e saídas, com base nos padrões fornecidos, torna-se possível a generalização de soluções, ou seja, a rede produz uma resposta que é próxima da esperada para qualquer valor de entrada inserido. O conjunto de passos utilizados para o treinamento da rede é chamado de algoritmo de aprendizagem.

Usualmente, o conjunto contendo todas as amostras de dados disponíveis de um sistema é dividido em duas etapas. A primeira delas é a etapa de treinamento, na qual se utiliza 60 – 90% dos dados disponíveis com o objetivo de aplicar o processo de aprendizado da rede. A segunda etapa é a fase de validação, onde é verificado se a capacidade de generalização da rede encontra-se em nível adequado, nesta etapa se utiliza 10 – 40% das amostras disponíveis.

Existem dois tipos principais de métodos de aprendizagem a serem aplicados a RNA, a aprendizagem supervisionada e a aprendizagem não supervisionada. Na aprendizagem supervisionada cada amostra de treinamento é composta pelo sinal de entrada e sua saída correspondente. Dessa forma, o algoritmo se comporta como um professor, ensinando qual a resposta correta a cada amostra apresentada na entrada. Os pesos sinápticos e *thresholds* da rede estão continuamente se ajustando de acordo com a discrepância entre as saídas produzidas em relação com as saídas esperadas pelo sistema. A rede é considerada treinada quando a diferença entre esses parâmetros encontra-se em determinado valor estabelecido. Em contrapartida, o aprendizado não supervisionado não requer qualquer conhecimento acerca das saídas desejadas pelo sistema.

Neste caso, a rede precisa organizar por conta própria quando existirem particularidades entre os elementos que compõem o conjunto de amostras.

O mecanismo de aprendizado aplicado para o processo de treinamento das RNA implementadas neste estudo foi o algoritmo de *backpropagation*. Esse método trata-se de uma forma de aprendizado supervisionado, no qual a RNA realiza o ajuste dos pesos sinápticos de seus neurônios com base no erro calculado entre a saída esperada e a saída apresentada pelo sistema. A implementação do algoritmo de *backpropagation* inicia-se na definição da função representativa do erro de aproximação, responsável por medir o desvio entre as respostas produzidas pelos neurônios de saída da rede em relação aos respectivos valores desejados.

De acordo com Silva *et al.* (2010), podemos utilizar a seguinte expressão para o cálculo do erro:

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_3} (d_j(k) - Y_j^{(3)}(k))^2 \quad (2.2)$$

Onde, $Y_j^{(3)}(k)$ é o valor produzido pelo j-ésimo neurônio de saída da RNA considerando-se a k-ésima amostra de treinamento, equanto que $d_j(k)$ é o seu respectivo valor desejado. Assumindo um conjunto de treinamento composto por p amostras, a medição da evolução do desempenho global do algoritmo *backpropagation* pode ser efetuada por meio da avaliação do "erro quadrático médio", definido por:

$$E_M = \frac{1}{p} \sum_{k=1}^p E(k) \quad (2.3)$$

A realização do processo de *backpropagation* se segue através de duas etapas similares para o ajuste dos pesos sinápticos de seus neurônios. A primeira destinada ao ajuste da matriz de pesos sinápticos referentes à camada neural de saída e a segunda ao ajuste das matrizes de pesos associadas às camadas intermediárias ou ocultas. Para a primeira etapa do processo foi aplicada a seguinte equação:

$$W_{ji}^{(c)}(t+1) = W_{ji}^{(c)}(t) + \eta \cdot \delta_j^{(c)} \cdot Y_i^{(c-1)} \quad (2.4)$$


Onde, $W_{ji}^{(c)}(t+1)$ é a matriz de pesos ajustada da camada de saída (peso conectado ao j-ésimo neurônio da camada de saída ao i-ésimo neurônio da camada anterior), $W_{ji}^{(c)}(t)$ é a matriz de pesos a ser corrigida, η é a taxa de aprendizagem do algoritmo *backpropagation*, $Y_i^{(c-1)}$ é o vetor cujos elementos denotam a saída do i-ésimo neurônio em relação a camada anterior e $\delta_j^{(c)}$ é definido como o gradiente local em relação ao j-ésimo neurônio da camada de

saída, sendo dado por:

$$\delta_j^{(c)} = (d_j - Y_j^{(c)}) \cdot g'(I_j^{(c)}) \quad (2.5)$$

Onde, $Y_j^{(c)}$ é o valor produzido pelo j-ésimo neurônio de saída da rede e d_j é o valor desejado para a saída do mesmo, $g'()$ denota a derivada de primeira ordem da função de ativação utilizada e $I_j^{(c)}$ é o vetor cujos elementos denotam a entrada ponderada em relação ao j-ésimo neurônio da camada de saída. Dessa forma, a expressão 2.4 ajusta os pesos dos neurônios da camada de saída da RNA levando-se em consideração a diferença observada entre as respostas produzidas por suas saídas em relação aos seus respectivos valores desejados, segundo Silva *et al.* (2010).

Figura 7 – Fases de treinamento do *backpropagation*



Fonte: Silva *et al.* (2010)

Em relação ao ajuste dos pesos sinápticos dos neurônios de camadas intermediárias não temos acesso de forma direta aos valores desejados para as suas saídas. Dessa forma, o treinamento dos neurônios pertencentes à camadas ocultas é efetuado por intermédio de estimativas dos erros de saída produzidos por aqueles neurônios da camada imediatamente posterior, os quais já foram previamente ajustados. Assim, somente após o ajuste dos neurônios da camada neural de saída é que se iniciam as correções dos pesos para os neurônios da camada oculta imediatamente anterior à camada de saída, onde tais ajustes serão baseados nos valores ponderados daqueles pesos sinápticos que já foram ajustados para os neurônios da camada de saída. De forma similar ao processo realizado na etapa anterior, a expressão aplicada para a correção da matriz de pesos sinápticos de camadas intermediárias é dada pela equação 2.4, onde

$\delta_j^{(c)}$ (gradiente local em relação ao j-ésimo neurônio da camada intermediária c) é dado por:

$$\delta_j^{(c)} = -\left(\sum_{k=1}^{n_{c+1}} \delta_k^{(c+1)} \cdot W_{kj}^{(c+1)}\right) \cdot g'(I_j^{(c)}) \quad (2.6)$$


Assim, a equação 2.6 ajusta os pesos dos neurônios da camada intermediária c, levando-se em conta a retropropagação do erro advinda a partir dos neurônios da camada de saída. Devemos ressaltar que se a arquitetura da RNA possuir mais de uma camada oculta, o processo aplicado é o mesmo, realizando sempre o ajuste da camada em questão tendo como base os valores dos pesos sinápticos já corrigidos da camada imediatamente posterior. A Figura 7 ilustra as duas fases de treinamento do algoritmo de *backpropagation*.

A função de ativação utilizada nos modelos implementados foi a função sigmóide, como ilustra a Figura 8. Os valores de entrada utilizados nas etapas de treinamento e validação das RNA modeladas foram os próprios valores de potência de saída do inversor em instantes anteriores, por exemplo, o valor de saída de potência do inversor em $(t + 1)$ (previsão) na arquitetura da Figura 17 é uma função dada por:

$$P(t + 1) = g(P(t), P(t - 1), P(t - 2), P(t - 3), P(t - 4)) \quad (2.7)$$

A modelagem e simulação dos sistemas foram desenvolvidos através do programa MATLAB.

Figura 8 – Função de ativação sigmóide



Fonte: Dozić e Urošević (2019)


2.5 Redes Neurais Artificiais Consideradas

O desenvolvimento desta pesquisa baseou-se na utilização de um modelo modificado de uma RNA Rede *Perceptron* Multicamadas, do inglês MLP. Esse modelo é denominado CFBP e para que o seu princípio de funcionamento seja melhor compreendido devemos entender de forma mais aprofundada a composição de sua estrutura e os modelos que o originaram. Dessa forma, especificaremos a Rede *Perceptron* e a Rede MLP.

2.5.1 Rede *Perceptron*

O *Perceptron* idealizado por Rosenblatt (1958) trata-se da forma mais simples de configuração de uma RNA, constituída de apenas uma camada neural e com a apenas um neurônio artificial nesta camada. Além disso, a rede *Perceptron* possui a arquitetura *feedforward*, inexistindo qualquer tipo de realimentação no fluxo dos dados processados. A Figura 9 ilustra uma rede *Perceptron*.

Figura 9 – Modelo de Rede *Perceptron*



Fonte: Silva *et al.* (2010)

Analisando a Figura 9 e tendo como base os modelos de neurônio demonstrados na Seção 2.2, podemos definir em termos matemáticos o processamento interno realizado pelo *Perceptron* pelas seguintes expressões:

$$u = \sum_{i=1}^n w_i x_i - \theta \quad (2.8)$$

$$y = g(u) \quad (2.9)$$

De forma resumida, as entradas (x_i) são ponderadas pelos seus respectivos pesos sinápticos (w_i) e a esta composição se adiciona o limiar de ativação (θ), fornecendo o argumento da função de ativação cujo resultado será a resposta do *Perceptron* aos estímulos fornecidos. É importante ressaltarmos que para este modelo normalmente as funções da ativação utilizadas são a função degrau e a função degrau bipolar.

Para entendermos o processo de treinamento de uma rede *Perceptron* devemos primeiramente analisar o seu comportamento como um típico caso de discriminador linear. Considerando uma rede do modelo em questão com apenas duas entradas e se utilizando da função de ativação degrau bipolar, temos:

$$y = \begin{cases} 1 & \text{se } \sum w_i x_i - \theta \geq 0 \Leftrightarrow w_1 x_1 + w_2 x_2 - \theta \geq 0 \\ -1 & \text{se } \sum w_i x_i - \theta < 0 \Leftrightarrow w_1 x_1 + w_2 x_2 - \theta < 0 \end{cases} \quad (2.10)$$

Assim, a fronteira de decisão será uma reta cuja equação é definida por:

$$w_1 x_1 + w_2 x_2 - \theta = 0 \quad (2.11)$$

Portanto, o *Perceptron* se comporta como um classificador de padrões cuja função é dividir classes que sejam linearmente separáveis, como ilustra a Figura 10.


O ajuste dos pesos e limiar do *Perceptron* é realizado por meio do processo de treinamento supervisionado. Assim, se a saída produzida divergir do resultado esperado as variáveis serão incrementadas proporcionalmente aos valores de seus sinais de entrada, caso contrário os pesos sinápticos e limiar permanecerão inalterados. Podemos representar em termos matemáticos as regras de ajustes por meio da expressão vetorial que se segue:

$$\mathbf{w}^{atual} = \mathbf{w}^{anterior} + \eta \cdot (d^{(k)} - y) \cdot x^{(k)} \quad (2.12)$$

Onde, \mathbf{w} é o vetor contendo limiar e pesos, $x^{(k)}$ é a k-ésima amostra de treinamento, $d^{(k)}$ é o valor desejado para a k-ésima amostra de treinamento, y é a saída produzida e η é a taxa de aprendizagem da rede.

A rede será considerada treinada quando inexistir erro entre os valores desejados e os valores produzidos.


Figura 10 – Fronteira de Separação



Fonte: Silva *et al.* (2010)

2.5.2 Redes Perceptron Multicamadas

As redes MLP se caracterizam pela presença de pelo menos uma camada intermediária de neurônios, apresentando uma arquitetura *feedforward* de camadas múltiplas e com o processo de treinamento realizado de forma supervisionada. A Figura 11 ilustra um modelo de rede MLP.

Figura 11 – Modelo de Rede *Perceptron* multicamadas

Fonte: Silva *et al.* (2010)

Analisando a Figura 11 podemos observar que o fluxo do processamento das informações é similar aos processos de outras redes apresentadas anteriormente. Os estímulos são apresentados à rede em sua camada de entrada, as camadas intermediárias através do ajuste dos pesos sinápticos e de seus limiares extraem as informações referentes ao comportamento do sistema e do ambiente em que se encontra e finalmente os neurônios da camada de saída fornecem a resposta disponibilizada pela rede.

O algoritmo de aprendizado aplicado no processo de treinamento de redes MLP é denominado *backpropagation* ou algoritmo de retropropagação do erro. A aplicação desse treinamento é constituída de duas fases, a propagação adiante e a propagação reversa.


Durante a fase de propagação adiante, aplica-se sinais de entrada na rede, os quais serão propagados normalmente através da rede até fornecer as saídas respectivas. Dessa forma, as respostas da rede com base nos pesos sinápticos e limiares atuais são apresentadas. Os valores produzidos são então comparados com os valores desejados e os desvios calculados serão utilizados durante a fase de propagação reversa para o ajuste de pesos e limiares de todos os neurônios que constituem a RNA.

Assim, a aplicação sucessiva das duas fases do treinamento realizam os ajustes necessários nos pesos sináptico e limiares dos neurônios, resultando na gradativa diminuição da soma dos erros produzidos pela rede MLP.

2.5.3 Redes CFBP

A rede CFBP utilizada nesse estudo consiste em um modelo modificado de uma rede MLP. A diferença se faz presente, pois na arquitetura da rede CFBP, cada entrada é conectada a cada uma das camadas da rede neural. Esta topologia permite que a correção dos erros durante a fase de treinamento por *backpropagation* apresente maior precisão.

Figura 12 – Modelo de Rede CFBP



Fonte: Moreno-Pérez *et al.* (2018)

Dessa forma, a rede CFBP torna-se capaz de aprender problemas complexos e estabelecer a dependência entre as entradas mais facilmente, resultando em uma melhor performance da rede nos resultados a serem produzidos. A Figura 12 ilustra a arquitetura de uma rede CFBP.

2.6 Conclusão

Diante disso, podemos compreender a concepção das RNA desde o primeiro modelo de neurônio artificial desenvolvido, entendendo o seu princípio de funcionamento, e as diferentes topologias de redes estruturadas a partir da combinação entre esses neurônios. Além disso, definiu-se que no trabalho desenvolvido foi utilizado a arquitetura de rede direta utilizando o algoritmo de treinamento denominado *backpropagation* em que as suas equações matemáticas, etapas e funcionamento foram demonstrados. Foi definido o modelo de RNA aplicado no estudo, denominado CFBP e a composição de sua arquitetura base também foi apresentada. Assim, no capítulo seguinte serão apresentados estudos utilizados como referência para o trabalho aqui desenvolvido em que foram realizadas aplicações de RNA e métodos para a realização de previsão de geração de energia FV.

3 ESTADO DA ARTE DA UTILIZAÇÃO DE REDES NEURAIIS ARTIFICIAIS PARA PREVISÃO SOLAR

De acordo com o que foi citado no Capítulo 2, inúmeros foram os modelos de Redes Neurais Artificiais desenvolvidos com o intuito de realizar a previsão de dados de geração de sistemas FV. Dessa forma, mencionaremos os principais estudos utilizados como base para o desenvolvimento dessa pesquisa, com o intuito de destacar as principais metodologias utilizadas nos dias atuais e constatar qual entre os modelos irá performar de forma mais eficiente para o problema proposto no trabalho em questão.

3.1 Metodologia Baseada em Rede Neural Artificial e Conjunto Analógico

No estudo descrito em Cervone *et al.* (2017) foi desenvolvida uma metodologia para a previsão de geração fotovoltaica de curto prazo de forma determinística e probabilística. O estudo citado propõe a utilização de RNA e um conjunto analógico, do inglês *Analog Ensemble* (AnEn), produzindo as previsões de geração dos sistemas em função de parâmetros meteorológicos e ambientais. Os dados para a alimentação do sistema foram coletados de três plantas fotovoltaicas localizadas em diferentes regiões da Itália, cada qual com as suas diferentes particularidades climáticas, condições essas que influenciam diretamente no comportamento dos padrões de geração apresentados.

As previsões climáticas realizadas para cada uma das estações são compostas de cinco variáveis que são utilizadas como entrada na rede a ser desenvolvida. Dessas variáveis, três foram previstas por meio do Sistema Regional de Modelagem Atmosférica, do inglês *Regional Atmospheric Modeling System* (RAMS), são elas: Irradiância Horizontal Global (IHG), Percentual de Cobertura de Nuvens (CN) e Temperatura a dois metros acima da superfície (T2M). As outras duas variáveis restantes foram calculadas em função do horário do dia e do período do ano, são elas: Azimute (AZ) e Elevação (EL), sendo de grande importância para quantificar a variabilidade sazonal da irradiância solar.

O algoritmo de *backpropagation* foi utilizado para o treinamento da RNA, aplicando pesos randômicos inicialmente para as conexões entre os nós e ajustando esses pesos com o intuito de minimizar o erro entre a entrada de dados e a previsão da rede. Dessa forma, a RNA foi estruturada para gerar previsões determinísticas da Potência Medida (PM) com base nas

variáveis descritas anteriormente e no tempo, como mostra a equação abaixo:

$$PM_t = RNA(IHG, CN, T2M, AZ, EL, T) \quad (3.1)$$

Nesse contexto, a estrutura da RNA foi definida da seguinte forma: seis nós de entrada, nove nós para a camada oculta e um nó de saída.

O algoritmo AnEn por sua vez, fornece previsões probabilísticas através do modelo de Previsão Numérica do Clima, do inglês NWP, que consiste em um conjunto de previsões anteriores e suas observações correspondentes. O ponto principal dessa técnica é que se previsões anteriores semelhantes podem ser encontradas um modelo de erro pode ser estimado e se aplicado irá melhorar a precisão dos dados produzidos pelo sistema.

Os métodos utilizados foram testados de forma individual e em conjunto para gerar previsões determinísticas e probabilísticas de geração fotovoltaica, para os dois tipos de previsão os melhores resultados observados foram apresentados quando RNA e AnEn performaram em conjunto, apresentando uma melhor precisão na estimativa dos dados. Em geral, essa metodologia pode ser aplicada a todas as situações onde estejam presentes dados de previsões passados associados a observações dos dados climáticos.

3.2 Metodologia Baseada em Máquina de Extremo Aprendizado

De acordo com o que foi apresentado em Hossain *et al.* (2017), desenvolveu-se uma Máquina de Extremo Aprendizado, do inglês *Extreme Learning Machine* (ELM), para a previsão da potência de saída de três sistemas fotovoltaicos conectados a rede e instalados sobre telhado do laboratório *PEARL* na Universidade de *Malaya*, Malásia.

Durante estudo utilizou-se dois diferentes horizontes para as previsões realizadas: previsão de potência de saída com uma hora de antecedência e com um dia de antecedência. É importante destacarmos as motivações para a utilização dos dois horizontes mencionados anteriormente, uma previsão precisa de curtíssimo prazo é fundamental para que se possa projetar um melhor sistema de gestão de energia fotovoltaica. Por outro lado, a previsão de curto prazo é crítica no sentido de se estabelecer uma melhor regulamentação do mercado de energia elétrica, além de auxiliar no processo de gestão de armazenamento energético em uma determinada região.

A ELM trata-se de um novo algoritmo de aprendizagem para redes neurais com apenas uma camada oculta que adotam do mecanismo de *feedforward* (os dados fluem em

uma única direção, sem retroalimentação), denominadas *single-hidden layer feedforward neural networks* (SLFNs). Nesse contexto, a ELM seleciona os nós ocultos de forma aleatória e analiticamente determina os pesos de saída das SLFNs. Esse tipo de mecanismo demonstrou ser milhares de vezes mais rápido do que os algoritmos de aprendizagem convencionais. Nesse estudo em questão, a ELM foi desenvolvida como um algoritmo de aprendizagem para SLFNs com diferentes funções de ativação.

Os resultados apresentados pelo modelo ELM proposto foram comparados com outros modelos populares como RNA e *support vector regression* (SVR). A comparação das previsões demonstrou que o modelo ELM performou melhor do que os outros métodos, apresentando uma precisão maior nos dados fornecidos, tanto para o horizonte de previsão de uma hora quanto para o horizonte de previsão de um dia. Além disso, o modelo proposto mostrou maior velocidade de processamento dos dados em todas as fases do experimento: treino e validação. Assim, a capacidade de previsão e precisão do modelo ELM indicou ser muito alta e confiável, confirmando a utilidade do método descrito.

3.3 Metodologia Baseada em Informações de *Sky-Imager* e Redes Neurais


O desenvolvimento de um modelo para a previsão de energia fotovoltaica é descrito em Anagnostos *et al.* (2019), capaz de produzir previsões de energia elétrica detalhadas com quinze minutos de antecedência para qualquer tipo de instalação. O modelo traduz a entrada de forma direta a uma curva de rendimento energético para a planta solar, minimizando as incertezas adicionais impostas pela utilização de diferentes modelos em conjunto. O estudo proposto utiliza imagens de satélite para fornecer entradas intermediárias ao algoritmo que serão repassadas para um modelo de RNA especializada que fará o tratamento devido dos dados.

Recursos específicos de imagem foram computados para cada uma das imagens capturadas pelo sistema e quantificados para que características especiais de imagens pudessem ser identificadas. Dessa forma, métricas como textura de imagem e valor de cores foram utilizadas pelo *software* de *sky-imager* para classificar as imagens obtidas, determinando o tipo dominante do tempo entre sete categorias pré-selecionadas. As categorias utilizadas no estudo são demonstradas na Figura 13.

Cálculos de rendimento de energia incluem de forma inerente alguma forma de regressão, desde que a energia adquirida depende do histórico de curto prazo do sistema de produção. Por essa razão, para esse estudo em questão foi selecionada uma rede auto-regressiva

não linear com entrada exógena, do inglês *non-linear auto-regressive network with exogenous input* (NARX), e constituída com uma estrutura de duas camadas ocultas. Assumindo que cada classe de nuvem possui uma característica própria, foi desenvolvido uma NARX para cada classe com o propósito de combinar essas sete redes com uma camada final de tratamento dos dados e que fornecerá os valores de saída do sistema.

Figura 13 – Amostras típicas das sete classes de nuvem



Fonte: Anagnostos *et al.* (2019)

A metodologia aplicada se provou útil para uma grande variedade de aplicações, tendo em vista que os resultados obtidos se demonstraram robustos e com uma performance superior aos modelos adotados como base no artigo em questão.

3.4 Metodologia Baseada em Cálculo Operacional

O estudo descrito em Zjavka (2020) aplicou a técnica computacional de rede neural polinomial diferencial, do inglês *Differential Polynomial Neural Network* (D-PNN), que atua decompondo a equação diferencial parcial geral, do inglês *Partial Differential Equation* (PDE), e dessa forma consegue modelar a dinâmica atmosférica local. Assim, torna-se possível o desenvolvimento de um método capaz de realizar previsões de potência fotovoltaica diária.

A metodologia proposta desenvolve de forma gradual uma estrutura com múltiplas camadas de redes neurais polinomiais, iniciando com apenas um nó e decompondo a PDE em

um conjunto de duas variáveis PDE. Isso permite uma representação complexa do padrão do clima atmosférico local. O treinamento da rede D-PNN é realizado com base em dados históricos espaciais fornecendo na saída a potência fotovoltaica.

O modelo apresentado demonstrou-se capaz de prever de forma precisa a variabilidade de potência fotovoltaica diária em grande parte dos dias monitorados. A performance do sistema se destacou principalmente em climas dinâmicos que possuem dados mais complexos e com padrões mais difíceis de serem previstos.

3.5 Metodologia Baseada em um Modelo Híbrido Assistido pela Decomposição de Wavelet

O método descrito em Kushwaha e Pindoriya (2019) aplica o efeito da decomposição de Wavelet em séries temporais de energia solar fotovoltaica em suas previsões. A implementação de uma RNA híbrida composta pelos modelos de Média Móvel Integrada Autoregressiva Sazonal, do inglês *Seasonal Autoregressive Integrated Moving Average* (SARIMA), e do *Link* Funcional Aleatório, do inglês *Random Vector Functional Link* (RVFL), é aplicada em conjunto com a transformada de Wavelet para a previsão de geração de energia solar fotovoltaica de curtíssimo prazo.

O estudo é desenvolvido voltado ao curtíssimo prazo pois esse tipo de informação pode proporcionar os seguintes benefícios:

- Proprietários de usinas solares podem ofertar mais precisamente no mercado, aumentando as suas receitas;
- Os participantes do mercado estão suscetíveis a penalidades caso exista grande desvio entre a geração real e a agendada. Uma previsão mais precisa é capaz de reduzir tais penalidades;
- Auxílio na previsão de carga de forma indireta;
- Proporcionar uma maior confiabilidade, estabilidade e qualidade de energia da rede;

O modelo de previsão adotado utiliza-se de dados de séries temporais de geração para a realização de suas previsões, aplicando a sazonalidade e a tendência desses dados para a determinação de seus valores futuros. A utilização de parâmetros climáticos não foi aplicada nesse experimento, pois apesar de melhorar a precisão dos modelos quando utilizados, esse tipo de informação exige alta resolução temporal e espacial, que geralmente não é disponível.

A aplicação de métodos de previsão híbridos convencionais utilizam algumas combinações das saídas obtidas de modelos constituintes para obter a previsão requerida. Entretanto o sistema apresentado aplica a estratégia de combinação na série decomposta, auxiliando na obtenção de previsões mais acertivas, pois a combinação ocorre em um nível de detalhamento mais avançado.

Foi observado que em condições de céu limpo a decomposição de Wavelet tende a reduzir a precisão da previsão. Isto ocorre em decorrência do aumento da complexidade no modelo que não é compensado pelas vantagens oferecidas devido a decomposição dos dados. Dessa forma, para as condições citadas apenas um dos modelos SARIMA ou RVFL atuando de forma isolada performou melhor do que o conjunto híbrido. Entretanto, em condições de céu nublado ou chuvoso, quando existe uma grande variação na geração de energia solar, a decomposição de Wavelet auxilia o modelo de previsão a performar melhor. Nesse contexto, o modelo híbrido SARIMA-RVFL proposto apresentou melhores resultados do que os seus modelos constituintes atuando de forma individual.

3.6 Metodologia Baseada em Redes Neurais Artificiais CFBP

O estudo descrito em Đozić e Urošević (2019) demonstra a aplicação de RNA para testar metas de política energética de longo prazo. Nesse contexto, é realizada a análise de um modelo do sistema energético da União Europeia (UE) por meio de RNA. Esse modelo é baseado na previsão de emissões de dióxido de carbono (CO_2) até 2050 levando em consideração a política energética vigente na UE. Essas políticas são descritas por dez indicadores chave, inseridos como entrada na RNA para a realização das previsões, permitindo o planejamento da redução de CO_2 através da correção desses indicadores. Dessa forma, os resultados de simulação obtidos podem ser utilizados como uma sugestão para a modificação das políticas existentes para que se alcance os objetivos ambientais traçados.

Nessa pesquisa, foi utilizado um modelo de RNA modificado com *perceptron* de multicamadas (MLP), denominado CFBP. Na arquitetura do método CFBP aplicado cada entrada é conectada a cada *layer* da rede, significando que a rede possui maior oportunidade para a correção de erros durante o processo de *back-propagation*, de forma que as próprias entradas corrigem os pesos de cada camada. A estrutura CFBP tem se provado uma rede poderosa para a solução de problemas complexos devido as sua capacidade de generalização e uma excelente correspondência entre os sistemas. Foi estabelecido que duas camadas ocultas seriam utilizadas

para esse sistema.

A descrição e quantificação das políticas energéticas para a previsão das emissões de (CO_2) foi realizada por meio de dez indicadores listados a seguir:

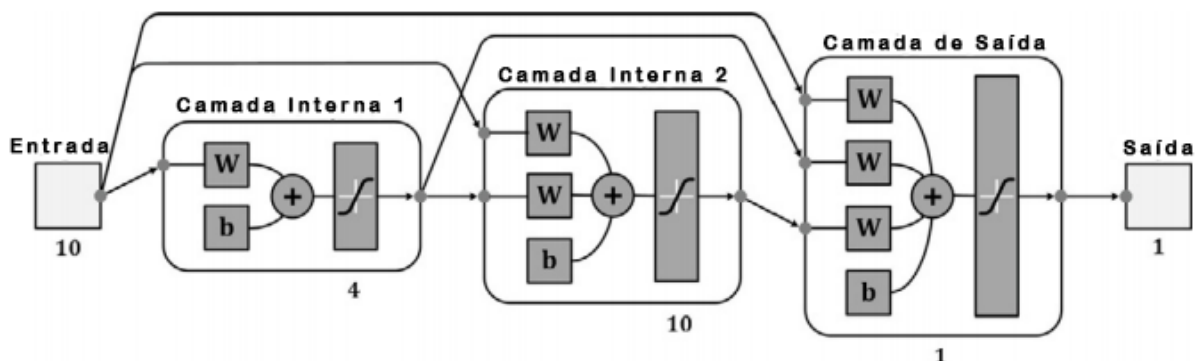
1. Produto Interno Bruto com base no poder de compra;
2. Temperatura média anual;
3. Fornecimento Total de Energia Primária (FTEP);
4. Consumo de eletricidade;
5. População;
6. Participação de fontes de energias renováveis no FTEP
7. Participação de energia nuclear no FTEP
8. Participação de energia de gás natural no FTEP
9. Participação de energia produzida do petróleo no FTEP
10. Participação de energia dos combustíveis sólidos no FTEP

A tendência de cada um dos indicadores utilizados foi calculada por ajuste de dados no período de 1990 até 2015 por um polinômio de primeiro grau, demonstrado em 3.2. Uma projeção desses valores foi aplicada a essa função polinomial para que se tornasse possível a determinação dos valores dos indicadores em todo o período da simulação, de 1990 até 2050.

$$y = ax + b \quad (3.2)$$

O programa MATLAB foi utilizado para a modelagem do sistema, simulação e processamento de dados. A figura 14 mostra a arquitetura final desenvolvida para a pesquisa.

Figura 14 – Arquitetura CFBP desenvolvida



Fonte: Đozić e Urošević (2019)

Nesse contexto, é importante ressaltar que a função de ativação nas camadas ocultas é a função tangente sigmóide, enquanto na camada de saída é utilizada uma função linear. Outro

fator a ser considerado é que durante a fase de treinamento da rede os dados originais foram utilizados (1990 - 2015), mas para as simulações foram utilizados dados originais e projeções dos indicadores. Durante a pesquisa, 100 RNA foram modeladas e testadas, entretanto apenas as que atenderam os critérios a seguir foram consideradas:

1. $RMSE < 2\%$
2. A previsão de emissão de CO_2 em 2050 estar entre 50% 70%

Dessa forma, apenas 30 RNA atenderam aos critérios estabelecidos.

Os resultados mostraram que o método CFBP modelou esse tipo de sistema de forma precisa e que possui a capacidade de prever o comportamento das emissões de CO_2 com a acurácia desejada.

3.7 Conclusão

Diante disso, para este capítulo foram apresentados exemplos práticos da aplicação de RNA para a previsão de dados complexos, demonstrando a capacidade de definição de padrões e generalização dos métodos aplicados pelos autores. Entre os estudos podemos destacar a aplicação demonstrada na Seção 3.6, em que a RNA do tipo CFBP foi utilizada como ferramenta para o planejamento das políticas energéticas vigentes na UE visando o alcance das metas de redução de CO_2 traçadas. A arquitetura CFBP utilizada apresenta maior oportunidade para a correção dos erros durante a fase de treinamento pela característica de alimentação das entradas em todas as camadas ocultas podendo resultar em uma melhor correlação entre entradas e saídas fornecidas. Por esse motivo justificou-se a utilização desse mesmo modelo no trabalho de conclusão de curso aqui desenvolvido.

4 METODOLOGIA PROPOSTA

A aplicação da metodologia proposta é apresentada no capítulo em que se segue. Na Seção 4.1 é demonstrado a usina em que o estudo foi aplicado, suas especificações, o tratamento de dados e os cenários analisados no trabalho. Na Seção 4.2 são apresentadas as arquiteturas desenvolvidas no estudo.

4.1 Descrição da Planta FV e Conjunto de Dados

Os dados utilizados para a aplicação da metodologia proposta foram coletados de uma planta FV instalada em uma residência localizada na cidade de Fortaleza, Ceará. O sistema de geração FV é constituído por 22 painéis FV policristalinos de 360 Wp da fabricante Canadian Solar, compondo um sistema de 7,92 kWp. Além disso, integra a instalação um inversor FV de 10 kW da fabricante ABB. A Figura 15 mostra a alocação dos módulos FV da planta analisada. A descrição do sistema FV utilizado no presente trabalho é demonstrada na Tabela 1.

Figura 15 – Alocação dos módulos da planta FV



Fonte: Próprio Autor

O fabricante do inversor utilizado no sistema FV a ser estudado disponibiliza uma plataforma de monitoramento em tempo real das grandezas elétricas que envolvem o processo de geração de energia elétrica, essa plataforma é denominada *Aurora Vision*. Através desse monitoramento é possível ter acesso ao histórico de geração da planta, à curva de potência de saída do inversor diária e entre outras medidas importantes para se atestar o funcionamento


adequado da planta FV. Para a aplicação da metodologia proposta neste trabalho foram utilizados os dados diários da curva de potência de saída do inversor para a realização das previsões de geração FV. O monitoramento faz a coleta dos dados de potência de saída do inversor em um tempo amostral de 15 minutos, construindo dessa forma a curva diária de potência do sistema. A Figura 16 exemplifica o monitoramento dessa grandeza ao longo de um dia.

Tabela 1 – Especificações da planta FV

Especificações	Planta
Quantidade de módulos	22
Potência do módulo (Wp)	360
Conxões em série	11
Conexões em paralelo (strings)	2
Tensão máxima do módulo (V)	39,6
Corrente máxima do módulo (A)	9,10
Peso do módulo (Kg)	22,5
Potência inversor (W)	10000
Tensão CC máxima do inversor (V)	900
Tensão CA máxima do inversor (V)	400
Eficiência máxima do inversor (%)	97,8

Fonte: Fabricantes: Canadian Solar, ABB

Figura 16 – Monitoramento da Potência de saída do inversor



Fonte: Monitoramento Aurora Vision

Nesse contexto, para a realização de treinamento e teste da metodologia desenvolvida foram extraídos os dados de potência de saída diária do inversor no período do dia 01 de Agosto de 2020 até 31 de Julho de 2021 (12 meses). Como dito anteriormente, a medida de potência instantânea na saída do inversor é aferida a cada 15 minutos, realizando 4 medições a cada hora. Assim, para o tratamento dos dados extraídos, foi realizada a média entre os valores registrados

na mesma hora, obtendo-se um valor médio de potência para cada hora do dia. É importante ressaltar que para o presente trabalho foram analisados ambos os cenários:

- Período completo do dia: Todas as medições realizadas ao longo do dia foram incluídas no processamento dos dados, incluindo os horários em que o sol não está presente (sem potência na saída do inversor);
- Período de funcionamento do sistema: Para o processamento dos dados foram incluídos apenas os horários em que o sistema FV encontra-se em funcionamento (existe potência na saída do inversor);

4.2 Aplicação da RNA

No presente trabalho foi utilizado o modelo de RNA denominado CFBP, no qual a sua estrutura e princípio de funcionamento foram introduzidos na Seção 2.5. A motivação para a aplicação desse tipo de estrutura ao problema abordado no presente trabalho provém da grande capacidade do modelo de se adequar à sistemas com alto grau de complexidade, como mostra o estudo realizado por Đozić e Urošević (2019). Na arquitetura do modelo CFBP cada entrada é conectada a cada camada da RNA, possibilitando, dessa forma, maior precisão na correção dos erros durante o processo de treinamento e conseqüentemente resultando em um aumento na probabilidade de precisão das previsões realizadas.

Nesse contexto, foi desenvolvida para efeito de comparação de performance uma RNA do tipo MLP. Entretanto, como dito anteriormente na Seção 4.1, foram considerados dois cenários para a utilização dos dados nas fases de treinamento e validação das RNA desenvolvidas: dados de período completo do dia e dados de período de funcionamento do sistema. Dessa forma, fez-se necessária a elaboração de uma arquitetura de RNA para cada cenário a ser analisado, resultando em 4 arquiteturas distintas desenvolvidas e descritas a seguir:

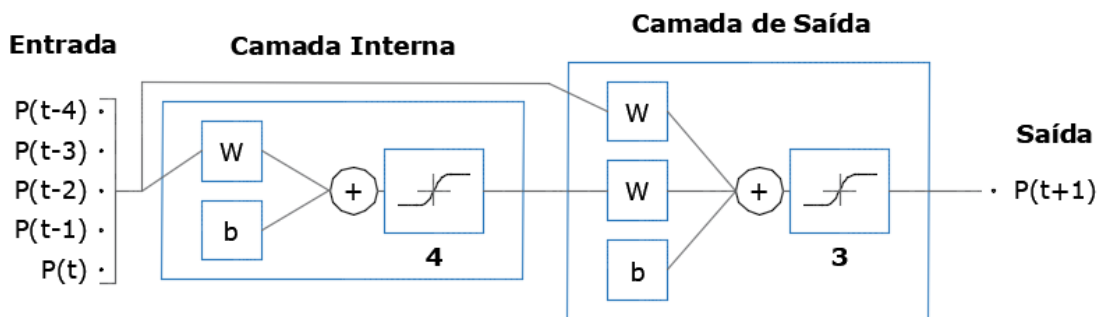
- Modelo 01: Rede CFBP utilizando os dados completos;
- Modelo 02: Rede CFBP utilizando os dados apenas em horários de Sol;
- Modelo 03: Rede MLP utilizando os dados completos;
- Modelo 04: Rede MLP utilizando os dados apenas em horários de Sol;

De acordo com Đozić e Urošević (2019), existem vários parâmetros que podem ser modificados para ajustar a arquitetura da RNA ao problema a ser tratado. Entre os parâmetros mais importantes podemos destacar o número de camadas internas (ou camadas escondidas), o número de neurônios em cada camada interna, a função de ativação e a função de treinamento

da RNA, tornando-se fatores essenciais para que a RNA seja capaz de representar o estado do sistema proposto. Assim, com base nesses fatores foram elaboradas as arquiteturas para os 4 modelos citados anteriormente.

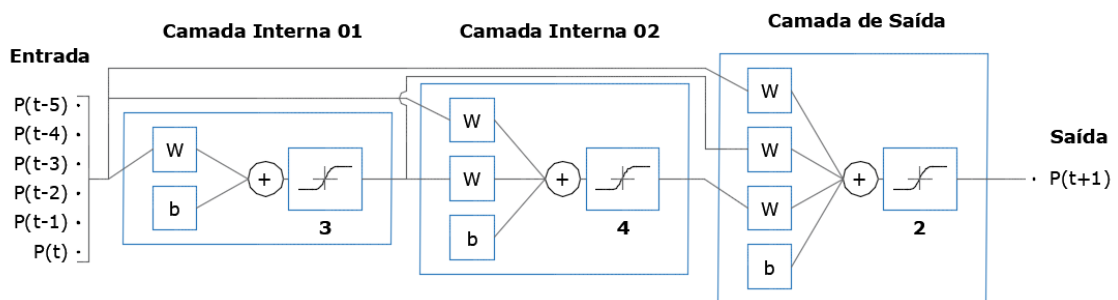
A rede CFBP para o cenário de utilização dos dados completos foi desenvolvida com 5 valores de entrada, possuindo duas camadas internas com 4 e 3 neurônios ocultos respectivamente e taxa de aprendizagem de 0,15. A Figura 17 demonstra a arquitetura do modelo 01. Para o cenário de utilização dos dados apenas em horários de Sol a rede CFBP foi elaborada com 6 valores de entrada, apresentando três camadas internas com 3, 4 e 2 neurônios ocultos respectivamente e taxa de aprendizagem de 0,25. A Figura 18 demonstra a arquitetura do modelo 02.

Figura 17 – Arquitetura CFBP dados completos



Fonte: Próprio Autor

Figura 18 – Arquitetura CFBP dados sem zeros

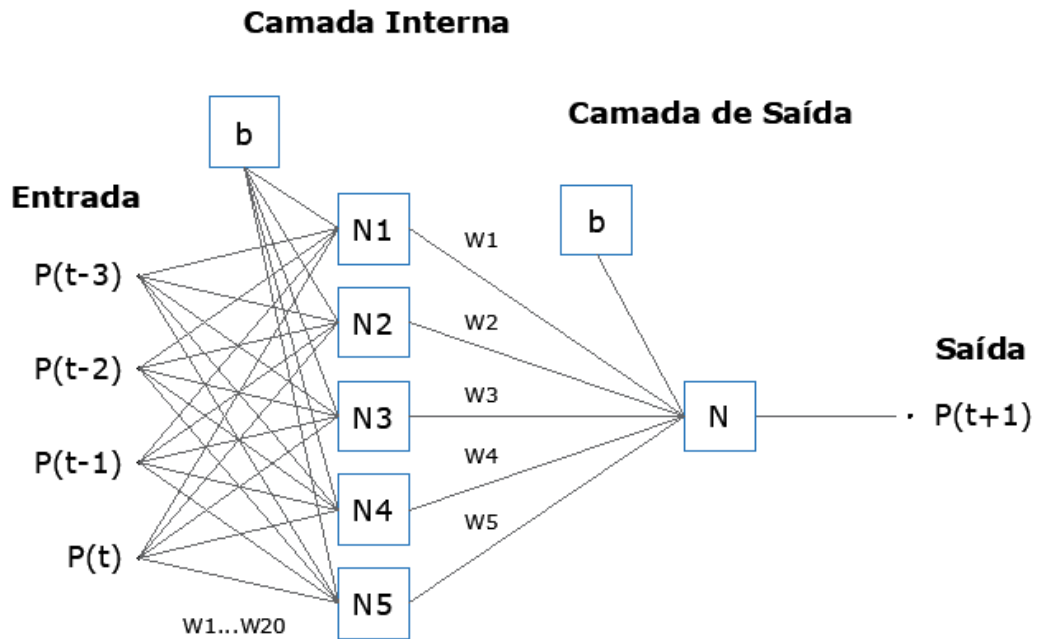


Fonte: Próprio Autor

A rede MLP para o cenário dos dados completos foi desenvolvida com 4 valores de entrada e uma camada interna contendo 5 neurônios, e uma taxa de aprendizagem de 0,35. A Figura 19 demonstra a arquitetura do modelo 03. Para o cenário de utilização dos dados apenas em horários de Sol a rede MLP foi elaborada com 3 valores de entrada e uma camada interna

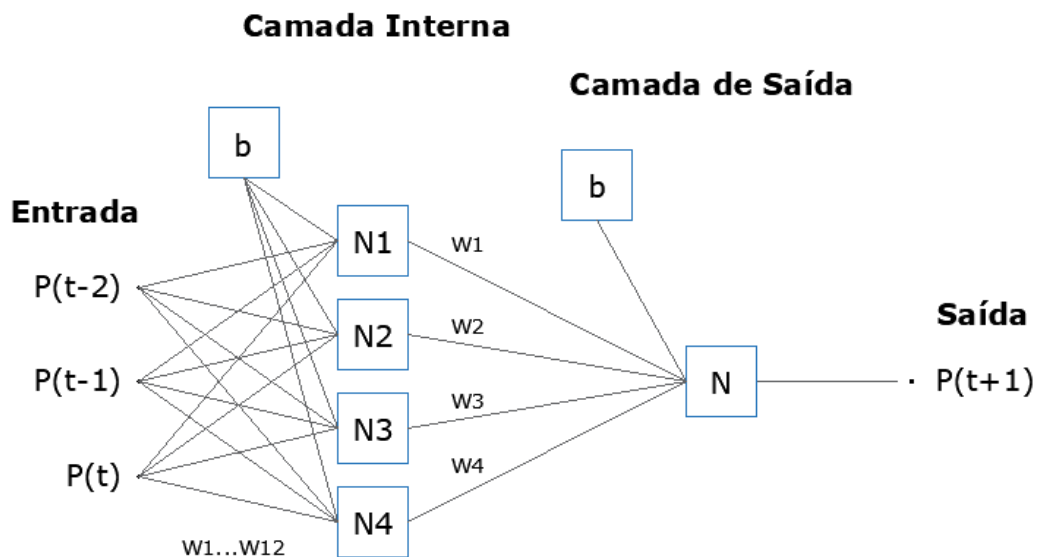
contendo 4 neurônios ocultos, e uma taxa de aprendizagem de 0,45. A Figura 20 demonstra a arquitetura do modelo 04.

Figura 19 – Arquitetura MLP dados completos



Fonte: Próprio Autor

Figura 20 – Arquitetura MLP dados sem zeros



Fonte: Próprio Autor

Devemos ressaltar o critério utilizado para a definição dos parâmetros utilizado para cada um dos modelos desenvolvidos, assim como o detalhamento da implementação e ajuste desses mesmos parâmetros e consequentemente a definição da arquitetura final utilizada em cada

RNA. A programação dos modelos foi implementada de forma manual, sem a definição da rede pronta, onde o ajuste dos parâmetros foram realizados através da simulação e apresentação dos melhores resultados em cada um dos modelos aplicados, por tentativa e erro. Dessa forma, os testes foram aplicados até a definição da arquitetura a ser utilizada por cada modelo. Em relação ao critério de parada adotado para o treinamento das RNA, foi definido durante a programação condições de iterações e erro considerados adequados para a aplicação desejada.

O mecanismo de aprendizado aplicado para o processo de treinamento das RNA implementadas foi o algoritmo de *backpropagation* descrito na Seção 2.4.

5 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados fornecidos pelos modelos desenvolvidos, a partir das condições previamente estabelecidas no capítulo 4. É importante ressaltar que a divisão dos dados entre as etapas de treinamento e validação das RNA aplicadas se fez da seguinte forma:

- Etapa de treinamento: 70% dos dados;
- Etapa de validação: 30% dos dados;

Além disso, o horizonte estabelecido para a realização das previsões de potência de saída do inversor foi de 1 hora, ou seja, trata-se de um modelo de previsão de curto prazo. Como visto anteriormente no capítulo 1, esse tipo de previsão se faz de grande importância na programação e despacho de energia elétrica e para projetar a gestão do sistema de energia.

A avaliação e comparação dos modelos foi realizada através de 3 métricas de análise de erro. A primeira delas foi o RMSE, ferramenta que demonstra como os dados estão alocados ao redor da melhor linha de ajuste. A segunda métrica utilizada foi o Erro Quadrático (R^2), que demonstra a razão da disparidade na variável dependente em relação a variável independente. A última métrica aplicada foi o MAE, que trata-se da comparação entre o dado observado e o previsto. De acordo com Yafouz *et al.* (2022), as métricas mencionadas são definidas pelas expressões a seguir, onde O_i são os dados observados, P_i são os dados previstos, O_m é a média dos dados observados e n é a quantidade de amostras:

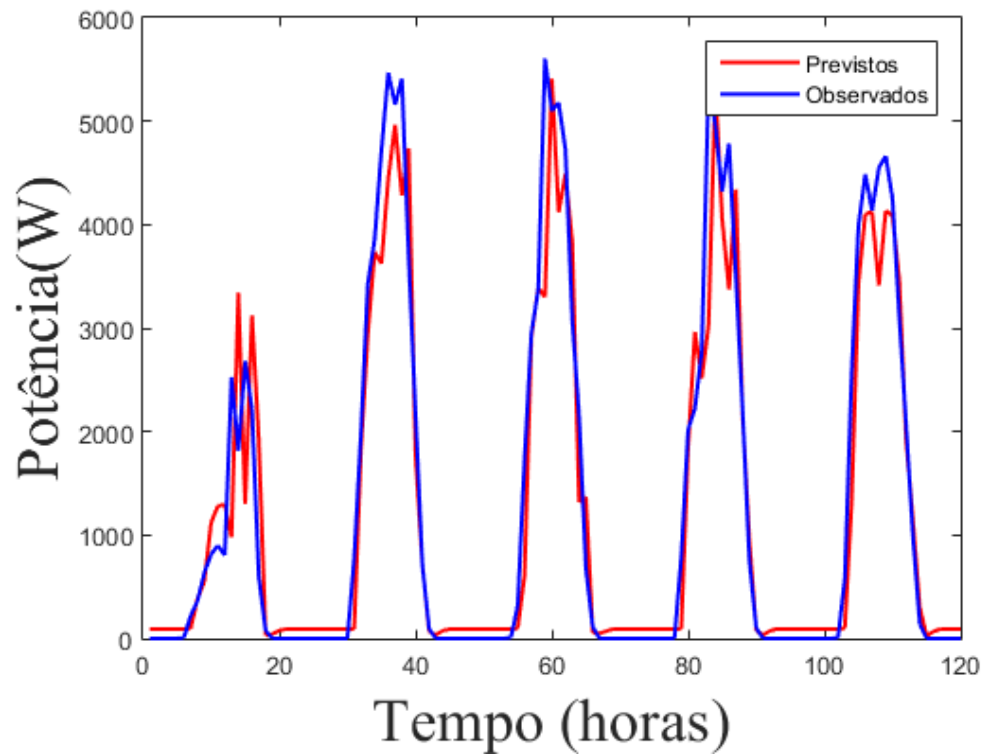
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad (5.1)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n O_i - P_i^2}{\sum_{i=1}^n O_i - O_m^2} \quad (5.2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \quad (5.3)$$


Os resultados obtidos pelas 4 arquiteturas desenvolvidas, treinadas e validadas foram plotados e apresentados nas figuras: Figura 21 (arquitetura CFBP para os dados completos), Figura 22 (arquitetura CFBP para os dados sem os zeros), Figura 23 (arquitetura MLP para os dados completos) e Figura 24 (arquitetura MLP para os dados sem os zeros), demonstrando a correlação entre os valores previstos e observados da potência de saída do inversor analisado.

Figura 21 – Resultados CFBP para dados completos




Fonte: Próprio Autor

Figura 22 – Resultados CFBP para dados sem os zeros




Fonte: Próprio Autor

Figura 23 – Resultados MLP para dados completos



Fonte: Próprio Autor

Figura 24 – Resultados MLP para dados sem os zeros



Fonte: Próprio Autor

Nesse contexto, analisando os dados apresentados, podemos observar que ambas as topologias de RNA desenvolvidas foram capazes de aprender os padrões dos dados fornecidos, tanto para o cenário de dados completos (24 horas do dia) como para o cenário de dados sem os zeros (dados contendo apenas horários com potência de saída do inversor positiva), demonstrando capacidade de generalização para o ambiente ao qual foram submetidas. Essa constatação comprova que as arquiteturas foram bem dimensionadas para o problema ao qual foram apresentadas, ou seja, os parâmetros de quantidade de entradas, de camadas intermediárias, de neurônios que compõem as RNA, assim como o processo de aprendizagem, função de ativação e taxa de aprendizagem estabelecidos foram adequados aos dados fornecidos.

A aplicação dos métodos para a análise de erro explicitados nas Equações 5.1, 5.2 e 5.3 foi apresentada na Tabela 2.

Tabela 2 – Resultado das métricas de erro aplicadas

Arquitetura	Dados	RMSE (W)	R^2 (%)	MAE (W)
CFBP	Completos	99,65	99,89	66,59
CFBP	Sem os zeros	54,14	99,97	43,41
MLP	Completos	99,68	99,98	68,80
MLP	Sem os zeros	65,97	99,96	52,20

Fonte: Próprio Autor

Através dos resultados apresentados pelas métricas de análise de erro podemos inferir acerca da performance de cada um dos modelos desenvolvidos. Em primeiro lugar, observamos que a arquitetura CFBP obteve um melhor desempenho em relação à arquitetura do tipo MLP, comprovando na prática que a correção dos erros durante a fase de treinamento apresenta maior precisão pelo fato de que as entradas encontram-se conectadas a cada uma das camadas intermediárias da RNA. Em segundo lugar, os modelos que se utilizaram dos dados contendo apenas os períodos de Sol para o treinamento e validação das RNA, ou seja, não incluindo os dados de potência nula do sistema FV, performaram de forma superior em relação ao outro grupo de teste. Assim, a tratativa de dados sem os zeros se mostrou uma forma mais eficiente para o processamento dos dados. Dessa forma, o modelo de RNA CFBP apresentou os melhores resultados utilizando os dados de potência de saída do inversor sem os zeros.

6 CONCLUSÕES

O potencial de inserção da fonte FV na matriz energética global requer uma adequada gestão de fornecimento de energia pelo órgão controlador, pois a grande variabilidade de geração ao longo do tempo é um dos grandes obstáculos para a aplicação dessa tecnologia. Assim, com o intuito da manutenção da estabilidade da rede elétrica e do suprimento energético, os métodos de previsão da geração FV apresentam-se como uma das principais soluções. O operador do sistema de gestão energética precisa de previsões confiáveis em diferentes horizontes de tempo, cada um com sua aplicabilidade. Isso justifica o crescente número de pesquisas acadêmicas relacionadas com o tema. Utilizando esse contexto como premissa, foi apresentada a metodologia a ser utilizada neste trabalho, baseada no desenvolvimento de uma RNA do tipo CFBP aplicada na previsão de geração de um sistema FV.

Em seguida foi realizada uma análise introdutória acerca de RNA, destacando o desenvolvimento histórico desse tipo de recurso e princípios de funcionamento. A utilização de uma RNA como um processador de dados inspirado nos circuitos cerebrais que busca desenvolver um comportamento inteligente através de seu processo de aprendizagem tornou-se comum na aplicação da resolução de problemas complexos da sociedade. Demonstrou-se primeiramente os modelos de neurônios, elementos de grande importância que compõem qualquer tipo de rede a ser desenvolvida. Foi mostrado o primeiro modelo de neurônio proposto por McCulloch e Pitts até o modelo geral do neurônio artificial que a partir do qual várias arquiteturas e modelos de RNA surgiram aplicando-se diferentes técnicas e combinações entre esses neurônios. Assim, foi definido na sequência as duas principais arquiteturas de redes aplicadas no estudo de RNA. Essa topologia depende da maneira pela qual os neurônios estruturam-se entre si e é de grande importância pois reflete diretamente no algoritmo de aprendizagem utilizado para treinar a rede. São duas as topologias tratadas neste trabalho, as redes diretas e as redes com ciclos. O princípio de aprendizado das RNA foi abordado em seguida, como um processo iterativo de ajustes aplicados a seus pesos sinápticos e níveis de bias.

Dessa forma, foi abordado no trabalho o desenvolvimento e funcionamento da rede perceptron e da rede MLP. Foram mencionados os principais estudos utilizados como base para o desenvolvimento desta pesquisa, que serviram para destacar as principais metodologias de previsão utilizadas nos dias atuais.

O método para a modelagem da previsão da potência de saída do inversor de um sistema FV foi apresentado. O objetivo foi determinar a curva da potência de saída do inversor

de uma usina residencial como uma metodologia para a previsão de geração de um sistema FV através de um modelo de RNA do tipo CFBP. A base de dados para a realização de treinamento e testes da RNA foi coletada através da plataforma de monitoramento denominada *Aurora Vision*, onde se extraiu os dados de potência de saída diários do inversor no período do dia 01 de agosto de 2020 até 31 de julho de 2021 (12 meses). Foi desenvolvida para efeito de comparação de performance uma RNA do tipo MLP, ambos os modelos foram aplicados a duas condições de dados fornecidas, a primeira considerando os dados de potência de saída do inversor do período completo do dia (24 horas) e segunda considerando os dados de potência de saída do inversor apenas com valores não nulos (período de funcionamento do sistema FV). Dessa forma, foram desenvolvidas 4 arquiteturas distintas e demonstradas no estudo. Assim, os modelos foram aplicados na previsão com 1 hora de antecedência da potência de saída do sistema FV.

Por último, foram apresentados os resultados fornecidos pelos modelos desenvolvidos. A avaliação das arquiteturas foi realizada através de 3 métricas de análise de erro distintas. Pode-se observar que ambas as topologias de RNA desenvolvidas foram capazes de aprender os padrões dos dados fornecidos com precisão aceitável, tanto para o cenário de dados completos quanto para o cenário de dados sem os zeros, demonstrando capacidade de generalização para o ambiente ao qual foram submetidas. Assim, podemos inferir que os modelos foram bem construídos para o ambiente em que foram submetidos, ou seja, os parâmetros definidos para cada arquitetura desenvolvida foram adequados em relação aos dados fornecidos.

Foi observado que a arquitetura CFBP apresentou maior precisão em relação a arquitetura MLP, conforme demonstrado na Tabela 2, comprovando que a correção de erros na fase de treinamento é mais assertiva, pois as entradas se conectam a cada uma das camadas intermediárias da RNA. Além disso, os modelos que utilizaram dos dados contendo os períodos de Sol para o treinamento e validação da RNA performaram de forma superior em relação ao outro grupo de teste, tornando-se a tratativa de dados sem os zeros uma forma mais eficiente para o processamento dos dados. Assim, o modelo de RNA do tipo CFBP utilizando os dados de potência de saída do inversor sem os zeros apresentou os melhores resultados nesse estudo, de acordo com a análise das métricas demonstradas na Tabela 2. A capacidade de previsão e precisão do modelo CFBP proposto demonstrou ser elevada e confiável para previsões em um horizonte de uma hora da potência de saída de sistemas FV conectados a rede, que se faz de grande importância na programação e despacho de energia elétrica e para a projeção da gestão do sistema de energia.

REFERÊNCIAS

- ABSOLAR, Associação Brasileira de Energia Solar Fotovoltaica . **Infográfico ABSOLAR**. 2021. Disponível em: <<https://www.absolar.org.br/mercado/infografico/>>. Acesso em: 29 julho 2021.
- ANAGNOSTOS, D.; SCHMIDT, T.; CAVADIAS, S.; SOUDRIS, D.; POORTMANS, J.; CATTHOOR, F. A method for detailed, short-term energy yield forecasting of photovoltaic installations. **Renewable Energy**, Elsevier, v. 130, p. 122–129, 2019.
- BARRETO, J. M. Introdução as redes neurais artificiais. **V Escola Regional de Informática. Sociedade Brasileira de Computação, Regional Sul, Santa Maria, Florianópolis, Maringá**, p. 5–10, 2002.
- BASSETTO, E. L.; DESTRO, J. F. Z.; FINOCCHIO, M. A. F.; MODESTO, R. A.; MARQUES, A. de S. Rede perceptron multicamadas (mlp) na estimativa da fração difusa da radiação global. In: **VII Congresso Brasileiro de Energia Solar-CBENS 2018**. [S.l.: s.n.], 2020.
- CERVONE, G.; CLEMENTE-HARDING, L.; ALESSANDRINI, S.; MONACHE, L. D. Short-term photovoltaic power forecasting using artificial neural networks and an analog ensemble. **Renewable Energy**, Elsevier, v. 108, p. 274–286, 2017.
- DAVID, T. M.; BUCCIERI, G. P.; RIZOL, P. M. S. R. Photovoltaic systems in residences: a concept of efficiency energy consumption and sustainability in brazilian culture. **Journal of Cleaner Production**, Elsevier, p. 126836, 2021.
- DOMINGOS, S. F.; MONTEIRO, L. G.; BOAVENTURA, W. do C. Estado da arte para previsão da radiação solar. In: **VII Congresso Brasileiro de Energia Solar-CBENS 2018**. [S.l.: s.n.], 2020.
- FERREIRA, A.; KUNH, S. S.; FAGNANI, K. C.; SOUZA, T. A. D.; TONEZER, C.; SANTOS, G. R. D.; COIMBRA-ARAÚJO, C. H. Economic overview of the use and production of photovoltaic solar energy in brazil. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 81, p. 181–191, 2018.
- GARLET, T. B.; RIBEIRO, J. L. D.; SAVIAN, F. de S.; SILUK, J. C. M. Value chain in distributed generation of photovoltaic energy and factors for competitiveness: A systematic review. **Solar Energy**, Elsevier, v. 211, p. 396–411, 2020.
- HAYKIN, S. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2007.
- HOSSAIN, M.; MEKHILEF, S.; DANESH, M.; OLATOMIWA, L.; SHAMSHIRBAND, S. Application of extreme learning machine for short term output power forecasting of three grid-connected pv systems. **journal of Cleaner Production**, Elsevier, v. 167, p. 395–405, 2017.
- INAGE, S.-i. Development of an advection model for solar forecasting based on ground data first report: Development and verification of a fundamental model. **Solar Energy**, Elsevier, v. 153, p. 414–434, 2017.
- JR, H. de F.; TRIGOSO, F. B.; CAVALCANTI, J. A. Review of distributed generation with photovoltaic grid connected systems in brazil: Challenges and prospects. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 75, p. 469–475, 2017.

- KUSHWAHA, V.; PINDORIYA, N. M. A sarima-rvfl hybrid model assisted by wavelet decomposition for very short-term solar pv power generation forecast. **Renewable Energy**, Elsevier, v. 140, p. 124–139, 2019.
- LACCHINI, C.; SANTOS, J. C. V. D. Photovoltaic energy generation in brazil–cost analysis using coal-fired power plants as comparison. **Renewable energy**, Elsevier, v. 52, p. 183–189, 2013.
- MARINHO, F. P.; ROCHA, P. A. C.; SILVA, M. E. V. da; LIMA, R. J. P.; NETO, J. P. de A. Resultados preliminares de previsão de irradiação solar de curto prazo através da combinação de processamento de imagens com algoritmos de aprendizagem de máquina. In: **VII Congresso Brasileiro de Energia Solar-CBENS 2018**. [S.l.: s.n.], 2020.
- MORENO-PÉREZ, J.; BONILLA-PETRICIOLET, A.; MENDOZA-CASTILLO, D.; REYNEL-ÁVILA, H.; VERDE-GÓMEZ, Y.; TREJO-VALENCIA, R. Artificial neural network-based surrogate modeling of multi-component dynamic adsorption of heavy metals with a biochar. **Journal of Environmental Chemical Engineering**, Elsevier, v. 6, n. 4, p. 5389–5400, 2018.
- NUNES, I.; SILVA, H. S. D. **Artificial neural networks: a practical course**. [S.l.]: Springer, 2018.
- ĐOZIĆ, D. J.; UROŠEVIĆ, B. D. G. Application of artificial neural networks for testing long-term energy policy targets. **Energy**, Elsevier, v. 174, p. 488–496, 2019.
- SILVA, I. d.; SPATTI, D. H.; FLAUZINO, R. A. Redes neurais artificiais para engenharia e ciências aplicadas. **São Paulo: Artliber**, v. 23, n. 5, p. 33–111, 2010.
- SILVA, R. M.; FERREIRA, P. H. F.; FONTENELE, L. F. A.; INACIO, C. O.; STONOGA, A.; RIBEIRO, E. H. F.; MARCHESI, B.; MOGNON, V. R.; PURIM, C. A.; CARNEIRO, G. L. *et al.* Estimativa da irradiância local utilizando inteligência artificial. In: **VII Congresso Brasileiro de Energia Solar-CBENS 2018**. [S.l.: s.n.], 2020.
- YAFOUZ, A.; ALDAHOU, N.; BIRIMA, A. H.; AHMED, A. N.; SHERIF, M.; SEFELNASR, A.; ALLAWI, M. F.; ELSHAFIE, A. Comprehensive comparison of various machine learning algorithms for short-term ozone concentration prediction. **Alexandria Engineering Journal**, Elsevier, v. 61, n. 6, p. 4607–4622, 2022.
- YANG, D.; KLEISSL, J.; GUEYMARD, C. A.; PEDRO, H. T.; COIMBRA, C. F. History and trends in solar irradiance and pv power forecasting: A preliminary assessment and review using text mining. **Solar Energy**, Elsevier, v. 168, p. 60–101, 2018.
- ZJAVKA, L. Photo-voltaic power daily predictions using expanding pde sum models of polynomial networks based on operational calculus. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 89, p. 103409, 2020.