

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA – CÂMPUS DE ILHA SOLTEIRA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

MANUEL CHICOMO CABRAL

**PREVISÃO DE IRRADIÂNCIA SOLAR, PARA FINS DE GERAÇÃO
FOTOVOLTAICA PARA BENGUELA – ANGOLA, USANDO
APRENDIZADO DE MÁQUINAS**

Ilha Solteira - SP
2024



MANUEL CHICOMO CABRAL

**PREVISÃO DE IRRADIÂNCIA SOLAR, PARA FINS DE GERAÇÃO
FOTOVOLTAICA PARA BENGUELA – ANGOLA, USANDO
APRENDIZADO DE MÁQUINAS**

Dissertação apresentada à Faculdade de Engenharia do Câmpus de Ilha Solteira – UNESP como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

Área de Concentração: Automação.

Orientadora: Prof. Dra. Anna Diva. P. Lotufo

Ilha Solteira - SP

2024

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

C117p Cabral, Manuel Chicomo.
Previsão de irradiância solar, para fins de geração fotovoltaica para Benguela – Angola, usando aprendizado de máquinas / Manuel Chicomo Cabral.
-- Ilha Solteira: [s.n.], 2024
82 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2024

Orientador: Anna Diva Plasencia Lotufo

Inclui bibliografia

1. Modelo preditivo . 2. Irradiância solar. 3. Energia renovável . 4. Aprendizado de maquina.


Amanda Sertori dos Santos

IMPACTO POTENCIAL DESTA PESQUISA

O presente trabalho possui impacto significativo em diversos domínios. Cientificamente, foi utilizada uma Rede Neural Artificial (RNA) para a previsão da irradiância solar global horizontal (GHI, do inglês *Global Horizontal Irradiation*) em Benguela, Angola. As RNAs podem ser aplicadas no setor de energia solar, podendo otimizar o dimensionamento e planejamento de sistemas fotovoltaicos e ajustando a produção de energia com base na previsão de GHI. No domínio da inovação, este trabalho facilita a previsão de GHI, aumentando a eficiência do despacho de energia fotovoltaica com um software simples e fácil de usar, incentivando o empreendedorismo no setor de energias renováveis. Economicamente, a pesquisa estimula o crescimento econômico e a geração de empregos na província de Benguela e em outras regiões de Angola, devido à expansão dos sistemas fotovoltaicos. Ambientalmente, o modelo contribui para a redução de CO₂ na indústria automotiva, fornecendo previsões de GHI para captação de energia solar durante a condução, sendo os automóveis equipados com painéis fotovoltaicos. A relevância do tema para Angola é destacada pelo apoio aos especialistas do setor energético, ajudando a atender à crescente demanda por energia limpa, crucial para a preservação ambiental.

POTENTIAL IMPACT OF THIS RESEARCH

This work has a significant impact in several areas. Scientifically, an Artificial Neural Network (ANN) was used to predict global horizontal solar irradiance (GHI) in Benguela, Angola. ANNs can be applied in the solar energy sector, optimizing the sizing and planning of photovoltaic systems and adjusting energy production based on the GHI forecast. In the field of innovation, this work facilitates GHI forecasting, increasing the efficiency of photovoltaic energy dispatch with simple and easy-to-use software, encouraging entrepreneurship in the renewable energy sector. Economically, the research stimulates economic growth and job creation in the province of Benguela and other regions of Angola, due to the expansion of photovoltaic systems. Environmentally, the model contributes to the reduction of CO₂ in the automotive industry, providing GHI predictions for capturing solar energy while driving, with cars equipped with photovoltaic panels. The relevance of the topic for Angola is highlighted by the support for experts in the energy sector, helping to meet the growing demand for clean energy, crucial for environmental preservation.

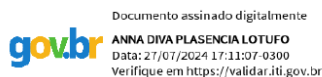
CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: PREVISÃO DE IRRADIÂNCIA SOLAR, PARA FINS DE GERAÇÃO FOTOVOLTAICAS PARA BENGUELA - ANGOLA, USANDO APRENDIZADO DE MÁQUINAS

AUTOR: MANUEL CHICOMO CABRAL

ORIENTADORA: ANNA DIVA PLASENCIA LOTUFO

Aprovado como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica, área: Automação pela Comissão Examinadora:



Profa. Dra. ANNA DIVA PLASENCIA LOTUFO (Participação Presencial)
Departamento de Engenharia Eletrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Profa. Dra. MARA LUCIA MARTINS LOPES (Participação Presencial)
Departamento de Matematica / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. KENJI NOSE FILHO (Participação Presencial)
Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas / Universidade Federal do ABC - UFABC

Ilha Solteira, 19 de julho de 2024

Dedico este trabalho aos meus pais de feliz memória, a professora Anna Diva pelo incentivo e mestria, a minha mãe Menga Adelina, à minha esposa pelo amor e parceria e para ao meu mano Cassoma pela mentoria e sabedoria.

AGRADECIMENTOS

Primordialmente a Deus, pela força de poder chegar até este momento, iluminação por ter me guiado quando tudo parecia sem luz, proteção quando me senti inseguro.

A minha estimada esposa Ngudi Paula Cabral, pela pontual presença apesar da distância, pelo encorajamento para catapultar barreiras que as vezes parecem intransponíveis.

Aos meus filhos, Chicomo, Chilula, Nzolane e Tchimbiambumlo, grato pelas emoções que me fazem vibrar a cada dia.

A minha mãe e filha Menga Adelina pelo amor, apoio e orações constantes.

Aos meus familiares, irmãos, Sande, Chilula, Rosa, Cassoma, Cecília e Julieta pela força e encorajamento, aos sobrinhos, João pela recepção e paciência, Mateus, Cláudio, Natália, Zita, Isabel e Lucas pelo incentivo. Aos meus cunhados, João Paulo, Dário, Glória, Moisés e João Lucombo. Aos meus manos Ito e Ana Marite, Esperança e Félix que se tornaram avós dos meus filhos.

A minha orientadora Prof.^a Dra. Anna Diva Plasencia Lotufo, por me ter aceito e tornar este sonho realidade, pelo carinho e apoio.

A Prof.^a Dra. Mara Lúcia Martins Lopes pela disponibilidade e carinho.

Ao prof. Dr. Carlos Minussi pelos conhecimentos partilhados e cordialidade.

Aos professores Drs. Carlos Santos e Thays Abreu, Dr. Sérgio Kurokawa pelo carinho e amizade.

Aos meus padrinhos, Avelino e Olga pelos conselhos e atenção. Aos meus compadres e suas parceiras Gilberto Mbuale e Carlos Diamantino pela presença na minha ausência.

Ao meu amigo Nelson de Almeida Africano pelo apoio incondicional que deu e tem dado, pois sem ele o sonho seria encurtado.

Aos colegas do laboratório, com particular realce ao Haislan, Reginaldo, Giovanni, Danielli, Ademir, Ivan, Paula Andrea e Salvador, que acabam sendo pilares dessa minha caminhada. Aos colegas amigos Hugo Yamanaka, Inés pela atenção. Ao meu mano Julino pelo companheirismo.

Aos meus amigos, Santiago, Dorotéia, Samuel, Sérgio, Bartolomeu, Valdemar e Monaly pelos incentivos em cada ligação feita. Aos meus manos da linha da frente, Adérito almeida, Ângelo Paulino e Carlos Guisado pela força e conselhos.

Aos meus pais de Ilha Solteira, dona Rosilda e o Sr. João Batista muito obrigado mesmo.

Ao pessoal da equipe limpeza, segurança e transporte, em especial a Sra. Fátima pelo café gostoso e o Sr. Romero pelas conversas mantidas ao longo das viagens.

Ao CNPq, pela concessão de bolsa de pesquisa (processo 131247/2023-9).

“Um fraco rei faz fraca a sua forte gente”

Napoleão Bonaparte.

RESUMO

Pesquisadores buscam aprimorar a utilização da irradiância global horizontal para geração de energia fotovoltaica, visando atender à crescente demanda energética e preservar o ecossistema. Assim, propor um modelo com boa capacidade preditiva para melhor responder a demanda cada vez mais crescente, facilitando a planificação e o dimensionamento assim como a manutenção, torna este trabalho de grande relevância em sistemas de geração de energia solar fotovoltaica. Este trabalho tem como propósito a implementação um modelo baseado em redes neurais artificiais para prever a irradiância global horizontal (GHI) horária a curto prazo para Benguela, Angola. Para isso, foi utilizada uma rede neural Perceptron de Múltiplas Camadas (MLP, do inglês, *Multilayer Perceptron*), com o objetivo de melhorar a eficácia da previsão de GHI e com isso auxiliar na otimização do aproveitamento da radiação solar no país. Os dados meteorológicos como, a temperatura, umidade relativa, pressão atmosférica e velocidade do vento, que serviram como variáveis de entrada, e a irradiância global horizontal como a variável de saída, foram obtidos a partir do *website* de dados da NASA e dados medidos através das estações meteorológicas da PRODEL localizadas na província de Benguela. As métricas de avaliação MAPE e RMSE foram utilizadas, resultando em um MAPE de 10,16% e 7,12%, e RMSE de 79,29 Wh/m² e 61,15 Wh/m² para estações seca e chuvosa, respectivamente.

Palavras-chave: modelo preditivo; irradiância solar; energia renovável; aprendizado de máquinas.

ABSTRACT

Researchers seek to improve the use of horizontal global irradiance for photovoltaic energy generation, aiming to meet growing energy demand and preserve the ecosystem. Therefore, proposing a model with good predictive capacity to better respond to increasingly growing demand, facilitating planning and sizing as well as maintenance, makes this work of great relevance in photovoltaic solar energy generation systems. This work aims to implement a model based on artificial neural networks to predict the short-term hourly global horizontal irradiance (GHI) for Benguela, Angola. For this, a Multilayer Perceptron (MLP) neural network was used, with the aim of improving the effectiveness of GHI prediction and thereby helping to optimize the use of solar radiation in the country. Meteorological data such as temperature, relative humidity, atmospheric pressure and wind speed, which served as input variables, and global horizontal irradiance as the output variable, were obtained from the NASA data website and data measured through by PRODEL meteorological stations located in the province of Benguela. The MAPE and RMSE evaluation metrics were used, resulting in a MAPE of 10.16% and 7.12%, and RMSE of 79.29 Wh/m² and 61.15 Wh/m² for dry and rainy seasons, respectively.

Keywords: predictive model; solar irradiance; renewable energy; machine learning.

LISTA DE FIGURAS

Figura 1 – Ilustração das componentes da irradiância global horizontal	30
Figura 2 – Mapa de África de irradiância global horizontal.....	34
Figura 3 – Mapa de África com as divisões regionais, realçando países usados para o estudo.	34
Figura 4 – Mapa de irradiância global horizontal da África do Sul	36
Figura 5 – Mapa de irradiância global horizontal do Egito.....	37
Figura 6 – Mapa de irradiância global horizontal de Angola.....	39
Figura 7 – Estrutura comparativa de um neurônio biológico e artificial.....	45
Figura 8 – Ilustração de um modelo não-linear de um neurônio.....	46
Figura 9 – Ilustração gráfica função degrau	47
Figura 10 – Ilustração gráfica da função linear	47
Figura 11 – Ilustração gráfica da função sigmoide.....	48
Figura 12 – Rede <i>feedforward</i> de uma única camada de neurônios de saída.....	50
Figura 13 – Rede <i>feedforward</i> com uma única camada oculta de neurônios.	50
Figura 14 – Rede recorrente com neurônios ocultos	51
Figura 15 – Esquemático do funcionamento do algoritmo de <i>backpropagation</i>	52
Figura 16 – Diagrama proposto das fases desenvolvida da metodologia.....	57
Figura 17 – Diagrama das variáveis de entrada e saída.....	58
Figura 18 – Diagrama de tratamento de dados	59
Figura 19 – Diagrama elucidativo da rede neural modelada e a especificação das entradas ...	61
Figura 20 – Fases de utilização da RNA	62
Figura 21 – Arquitetura da RNA desenvolvida	66
Figura 22 – Resposta da rede durante a fase de treinamento para a estação seca	67
Figura 23 – Resposta da rede durante a fase de treinamento para a estação chuvosa	67
Figura 24 – Comparação entre as respostas dada pela rede, valor real e das variáveis.....	68
Figura 25 – Resultado previsto pela rede (estação chuvosa).....	69
Figura 26 – Resultado previsto pela rede (estação seca).....	70

LISTA DE QUADROS

Quadro 1 – Valores de GHI dos países selecionados segundo as divisões regionais.....	33
Quadro 2 – Demonstração dos resultados de acordo as estações	71

LISTA DE ABREVIATURAS E SIGLAS

IA - Inteligência Artificial

INE - Instituto Nacional de Estatística

AM - Aprendizado de Máquina

RMSE - Root Mean Square Error (Raiz do Erro Quadrático Médio)

INAMET - Instituto Nacional de Meteorologia

RBFNN - Radial Basis Function (Função de Base Radial)

GRNN - General Regression Neural Network (Rede Neural de Regressão Generalizada)

MAPE - Mean Absolute Percentage Error (Erro Percentual Absoluto Médio)

RNA - Redes Neurais Artificiais

LSTM - Long Short-Term Memory (Memória de Longo Prazo)

RNN - Rede Neural Recorrente

GHI - Global Horizontal Irradiation (Irradiação Horizontal Global)

PRODEL - Empresa Pública de Produção de Energia

DNI - Direct Normal Irradiance (Irradiância Normal Direta)

DHI - Diffuse Horizontal Irradiance (Irradiância Horizontal Difusa)

SI - Sistema Internacional de Unidades

WRDC - World Radiation Data Center (Centro de dados de radiação mundial)

LISTA DE SÍMBOLOS

Km - Quilômetros

MW - Mega Watts

°C - Grau Celsius

θ - Ângulo zenital

β - Ângulo de inclinação

δ - declinação do ângulo

Wh/m² - Watt hora por metros quadrados

W/m² - Watt por metros quadrados

GW - Giga Watt

kWh/m²/ano - Quilo Watts hora por metros quadrados por ano

m/s -Metros por segundo

kPa - Quilo Pascal

g/kg - Grama por quilograma

SUMÁRIO

1	INTRODUÇÃO	17
1.1	CONTEXTUALIZAÇÃO	17
1.2	OBJETIVOS	19
1.2.1	Objetivo Geral.....	19
1.2.2	Objetivos Específicos	19
1.3	JUSTIFICATIVA	20
1.4	ORGANIZAÇÃO DO TRABALHO	21
2	ESTUDOS CORRELATOS.....	23
2.1	INTRODUÇÃO	23
2.2	MODELO DE MINERAÇÃO DE DADOS	23
2.3	MODELO DE CIRCUITO IDEAL	24
2.4	MODELO BASEADOS EM PROGRAMAÇÃO GENÉTICA MULTIGENE (PGMG)	25
2.5	MODELO BASEADOS EM RNA.....	26
2.6	CONSIDERAÇÕES FINAIS DO CAPÍTULO	27
3	RADIAÇÃO SOLAR	29
3.1	INTRODUÇÃO.....	29
3.2	IRRADIÂNCIA GLOBAL HORIZONTAL.....	30
3.3	IRRADIÂNCIA GLOBAL HORIZONTAL NA SUPERFÍCIE TERRESTRE ...	31
3.3.1	Irradiância global horizontal na África.....	32
3.3.2	Impacto da irradiância global horizontal.....	35
3.3.2.1	Impacto da irradiância global horizontal no setor energético da África do Sul	35
3.3.2.2	Impacto da irradiância global horizontal no setor energético do Egito	36
3.3.2.3	Impacto da Irradiância global horizontal no setor energético de Angola	38
3.4	FATORES QUE INFLUENCIAM NA PREVISÃO DE IRRADIÂNCIA GLOBAL HORIZONTAL.....	40
3.4.1	Influência da temperatura atmosférica	41

3.4.2	Influência da umidade relativa do ar.....	41
3.4.3	Influência da pressão atmosférica.....	41
3.4.4	Influência da velocidade do vento.....	42
3.5	CONSIDERAÇÕES FINAIS DO CAPÍTULO.....	42
4	REDES NEURAIS ARTIFICIAIS.....	44
4.1	INTRODUÇÃO.....	44
4.2	NEURÔNIOS ARTIFICIAIS.....	44
4.2.1	Função de ativação.....	46
4.2.2	Arquitetura das RNAs.....	49
4.2.3	Aprendizagem das RNAs.....	51
4.2.4	Algoritmo de regularização Bayesiana.....	53
4.2.5	Avaliação de desempenho.....	54
4.3	CONSIDERAÇÕES FINAIS DO CAPÍTULO.....	56
5	METODOLOGIA PROPOSTA.....	57
5.1	INTRODUÇÃO.....	57
5.2	TRATAMENTO DOS DADOS DA RNA.....	58
5.3	DESENVOLVIMENTO DA ARQUITETURA DA RNA.....	60
5.4	METODOLOGIA DE TREINAMENTO DA RNA.....	61
5.5	METODOLOGIA PARA AVALIAÇÃO DE DESEMPENHO.....	62
5.6	TESTE E IMPLEMENTAÇÃO DO MODELO DA RNA.....	63
5.7	MONITORAMENTO E MANUTENÇÃO DO MODELO DA RNA.....	64
5.8	CONSIDERAÇÕES FINAIS DO CAPÍTULO.....	64
6	RESULTADOS E DISCUSSÃO.....	66
7	CONSIDERAÇÕES FINAIS.....	72
7.1	CONCLUSÕES.....	72
7.2	TRABALHOS FUTUROS.....	73
	REFERÊNCIAS.....	74

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

A República de Angola situa-se entre os paralelos 4° 22' e 18° 02' e os meridianos 4° 05' e 11° 41' a Este de Greenwich, no Hemisfério Sul, na parte Ocidental da África Austral e ocupa uma área de 1.246.700 Km² (Zau, 2002). A população estimada de Angola em 2014 era de cerca de 25 milhões de habitantes, com uma taxa de crescimento anual de 3,3% (INE, 2014).

Como a maioria dos países africanos, Angola dispõe de um clima tropical e, portanto, tem duas estações principais: A estação seca conhecida como cacimbo e a estação chuvosa (INAMET, 2021). Durante o cacimbo, que ocorre de maio a setembro, a temperatura é, geralmente, mais baixa, com menores temperaturas nas regiões central e sul do país.

No planalto a temperatura pode atingir os 5°C, enquanto que a temperatura média anual máxima é de 27°C. Na estação chuvosa, que ocorre de outubro a abril, as temperaturas são geralmente mais altas, com uma média de 30°C (INAMET, 2021).

Desta forma, é possível observar que Angola é um país com alto potencial de produção energia fotovoltaica, que depende da radiação solar. A radiação solar tem sido considerada a fonte de energia mais abundante e importante do planeta (Gana; Akpootu, 2013).

A energia renovável é hoje considerada um ente precípua para o desenvolvimento das economias com relevância direta no crescimento de várias sociedades, com maior realce para aquelas populações que se encontram em zonas remotas ou de difícil acesso, que podem fazer desta, a sua fonte alternativa de energia devido à dificuldade no processo de transmissão e distribuição da energia de fontes convencionais, tendo como exemplo as hídricas, bem como fatores de caráter natural.

O fator econômico, a eficácia, e o fácil manuseio tornam a energia solar um recurso energético mais fiável quando comparado a outros tipos de energia renovável, sendo a mais valiosa fonte de energia renovável e limpa; a energia solar é derivada diretamente do sol na forma de radiação (Qazi *et al.*, 2015).

Estimar o desempenho de energia solar ou mesmo quando para a sua projeção é fundamental a obtenção do conhecimento e um estudo pormenorizado sobre a radiação solar de modo que os objetivos preconizados sejam alcançados. A previsão de radiação solar é necessária, pois, foi identificada como um dos parâmetros mais importantes no projeto de dispositivos de conversão de energia solar (Qazi *et al.*, 2015). No entanto, para a maioria dos países em desenvolvimento, a medição da radiação solar não é facilmente obtida devido a

incapacidade em adquirir os instrumentos de medição necessária e as técnicas operacionais utilizadas nos instrumentos disponíveis (Kuhe; Achirgenda; Agada, 2018).

Em Angola, apesar das dificuldades existentes, a cooperação com os Estados Unidos da América no setor energético, com particular realce em energia renovável, tem vindo a capacitar os técnicos bem como apetrechar algumas unidades ou centrais de geração fotovoltaicas (Angola, 2014).

O aprendizado de máquina (AM) é um campo de estudo da Inteligência Artificial (IA) que busca ensinar máquinas a lidar com dados de forma mais eficiente (Haykin, 1999). No contexto da energia solar, algoritmos de AM são utilizados para prever a radiação solar incidente e para otimizar o gerenciamento de recursos energéticos. Esses algoritmos fazem uso de séries históricas ou temporais de parâmetros meteorológicos medidos localmente como dados de entrada (Viscondi; Souza, 2021).

As redes neurais artificiais (RNAs) desempenham um papel importante nesse processo. Uma RNA é um processador massivamente distribuído e paralelo, constituído por unidades de processamento simples, chamadas de neurônios, que armazenam conhecimento experimental e o tornam disponível para uso. Assemelhando-se ao cérebro humano, as RNAs adquirem conhecimento do ambiente através de um processo de aprendizagem, conhecido como treinamento, e armazenam esse conhecimento nas conexões entre os neurônios, chamadas de pesos sinápticos (Haykin, 1999).

Diversos estudos têm demonstrado a eficácia das RNAs na previsão da radiação solar e da produção de energia solar. Esses algoritmos têm se mostrado consistentemente eficazes na previsão, proporcionando um desempenho superior em comparação com outros métodos (Yadav; Chandel, 2012).

Este trabalho propõe a implementação da previsão da irradiância solar para fins de geração fotovoltaicas na província de Benguela utilizando uma RNA. Como entrada da rede, foram considerados atributos meteorológicos desta mesma região.

Vale ressaltar que a província de Benguela, em comparação com outras províncias do país, dispõe de uma das mais altas taxa de temperatura do país, só atrás da província de Luanda, (INAMET, 2021); Apesar de ser uma província com potencial econômico muito elevado e dispor de duas centrais fotovoltaicas, não foi possível encontrar na literatura nenhum estudo específico de previsão de radiação solar para esta região. Então, um dos objetivos deste trabalho é melhorar a eficiência da geração da energia solar utilizando uma RNA. E, desta forma, apoiar o planejamento e a operação do sistema de energia, pois o sistema de previsão de radiação solar

pode fornecer informações valiosas para o planejamento e a operação do sistema de energia bem como a manutenção do equilíbrio entre a oferta e a demanda da energia.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

O trabalho tem como objetivo geral, desenvolver um modelo de aprendizado de máquina para melhorar a precisão da previsão da irradiância solar em curto prazo ($h+1$) e otimizar a geração de energia fotovoltaica, nos municípios da Baía-Farta e do Lobito na comuna do Biópio, na província de Benguela. Para previsão, será utilizada a série histórica contendo 5 diferentes dados meteorológico horários e diários coletados nas diferentes centrais fotovoltaicas, onde na central fotovoltaica do Biópio ocorreu entre 1 de julho de 2023 a 1 de janeiro de 2024, e na central fotovoltaica da Baía-Farta ocorreu entre 31 de março de 2023 a 1 de janeiro de 2024.

1.2.2 Objetivos Específicos

Considerando o exposto, torna-se essencial:

1. Coletar e analisar dados históricos de irradiância solar e outros parâmetros meteorológicos nas estações meteorológicas das centrais fotovoltaicas do Biópio e da Baía – Farta;
2. Estudar e entender trabalhos em que são usados algoritmos e métodos relacionados a previsão de irradiância horizontal global (GHI);
3. Realizar uma análise de sensibilidade para identificar os parâmetros meteorológicos mais influentes na previsão de irradiância solar;
4. Compreender e diferenciar os conceitos basilares inerentes a GHI e seu impacto a nível do continente africano e em especial Angola;
5. Treinar o modelo usando os dados coletados, aplicando técnicas de retropropagação para garantir a robustez do modelo;
6. Avaliar o desempenho do modelo usando métricas como por exemplo, a raiz do erro quadrático médio (RMSE) e o erro médio percentual absoluto (MAPE).

1.3 JUSTIFICATIVA

O crescimento da energia solar no mundo tem aumentado devido ao fator econômico, à eficiência na geração e ao fácil manuseio. Isso contribui para a distribuição progressiva da energia solar, impulsionando o crescimento econômico de muitos países e reduzindo os impactos ambientais das fontes de energia tradicionais. Assim, é cada vez mais necessário migrar para uma matriz energética baseada em fontes renováveis (Fiorin *et al.*, 2011).

O potencial solar em Angola, está estimado em 17,3 GW repartidos em 368 projetos. Dois já estão em operação desde julho de 2022 na província de Benguela com uma capacidade de geração de 268 MW e mais dois encontram-se em fase de construção nas províncias de Luanda e Malanje, com uma capacidade estimada de 500 MW (Angola, 2017).

A energia solar acaba tornando-se numa das fontes de energia mais promissoras e sustentáveis disponíveis hoje. A aplicação econômica e eficiente da energia solar é possível devido à abundante luz solar disponível durante todo o ano no Paquistão (Khan; Gadiwala, 2013), em Angola a condição é semelhante. A geração fotovoltaica é uma fonte de energia considerada limpa, inesgotável, global e renovável para a produção de eletricidade. Além disso, outra motivação para a disseminação da geração de eletricidade fotovoltaica é a emissão zero de dióxido de carbono na atmosfera (Routhier; Honsberg, 2018). No entanto, a eficiência da geração de energia solar depende fortemente da irradiação solar, que pode variar significativamente devido a fatores como localização geográfica, condições climáticas e hora do dia.

Benguela, uma cidade costeira em Angola, tem um grande potencial para a geração de energia solar devido à sua localização geográfica favorável e ao clima predominantemente ensolarado (INAMET, 2021). Não obstante, a falta de um modelo de previsão precisa de irradiância solar pode limitar a eficiência e a confiabilidade da geração de energia solar.

O uso de técnicas de aprendizado de máquina para prever a irradiação solar pode superar esses desafios. O aprendizado de máquina usa algoritmos para analisar grandes conjuntos de dados históricos de variáveis meteorológicas e a irradiação solar para fazer previsões (Shah *et al.*, 2016). Essas previsões podem ser usadas para otimizar a geração de energia solar.

Portanto, este trabalho de dissertação visa desenvolver um modelo de aprendizado de máquina para prever a irradiação solar em Benguela, Angola, com o objetivo de melhorar a geração de energia fotovoltaica. Acredita-se que este trabalho não só contribuirá para a pesquisa acadêmica na área de energia solar, mas também terá implicações práticas significativas para a geração de energia solar em Angola e em outros países.

1.4 ORGANIZAÇÃO DO TRABALHO

Os objetivos propostos nortearam o presente trabalho, que está dividido em 7 capítulos, sendo o primeiro capítulo o introdutório.

O capítulo 2 apresenta estudos correlatos, no qual é exposta a importância deste campo de estudo, permitindo identificar e compreender as relações entre os diferentes trabalhos apresentados e tirar ilações de como cada um destes pode contribuir para desenvolver o modelo que se propôs, visando a otimização da previsão.

Capítulo 3 apresenta inicialmente o conceito das palavras chaves que norteiam o trabalho, como radiação solar e irradiância solar, com o objetivo de facilitar o entendimento do mesmo. Em seguida, fez-se um estudo para aferir os níveis de GHI no continente, sendo que, para facilitar e dirimir a complexidade teve-se em conta a divisão do continente de acordo com as regiões existentes, analisando dois países de cada região. A compreensão do impacto da GHI nos dois países mais industrializados do continente sendo a África do Sul e o Egito foram fundamentais para poder entender o nível de aproveitamento que Angola está tendo e que caminhos deve trilhar para seguir o rumo dos dois países que melhor aproveitam a disponibilidade da radiação solar.

Por fim procurou-se compreender também a influência de cada uma das variáveis de entrada na previsão de GHI.

O capítulo 4 apresenta os pontos principais melhor se compreender as RNAs e como elas funcionam ou são aplicadas, facilitando assim o entendimento do aprendizado de máquina. Dentre muitos pontos abordados destacam-se a comparação de um neurônio artificial a um biológico; o aprendizado não supervisionado ou sem professor. E para finalizar teve-se em conta as métricas como o MAPE e o RMSE para avaliação de desempenho como recomendado na literatura.

Capítulo 5 apresenta a metodologia proposta abordando de forma sistemática as particularidades de cada uma das fases propostas. O tratamento dos dados sem desprimor as restantes fases, destaca-se pela peculiaridade e sensibilidade como sendo uma das fundamentais, seguida do treinamento da rede e validação do modelo.

Por fim, traz-se a implementação da rede que é seguida pelo monitoramento e manutenção do modelo com vista a não perder a eficácia deste.

O capítulo 6 apresenta a quantidade de dados obtidos durante a pesquisa sendo estes a fonte da análise e discussão dos resultados, levando a interpretação exaustiva tendo em conta seu impacto na tomada de decisão.

Por fim, no Capítulo 7 são apresentadas as considerações finais sobre o trabalho desenvolvido, apresenta-se também as sugestões para trabalhos futuros.

2 ESTUDOS CORRELATOS

2.1 INTRODUÇÃO

Neste capítulo são apresentados estudos correlatos, cujo objetivo visa demonstrar a importância deste campo de estudo e justificar a necessidade da implementação de um modelo para esta pesquisa, pois, a previsão de irradiância solar é um campo de estudo importante para a otimização da geração de energia fotovoltaica.

Para este contexto, várias abordagens e modelos foram desenvolvidos com o objetivo de prever a irradiância solar. Este trabalho centra-se em quatro modelos, apesar de existirem outros tantos e cada um com suas próprias características.

2.2 MODELO DE MINERAÇÃO DE DADOS

Entende-se por modelos de mineração de dados como sendo ferramentas poderosas que permitem a análise e extração de informações importantes de grandes conjuntos de dados, com vista a facilitar a descoberta de padrões e a previsão de tendências; os modelos de mineração, são aplicados em várias áreas, a destacar como exemplo, segurança e saúde, finanças, previsão, marketing, com objetivo de melhorar e otimizar os processos.

Assim, a aplicação de minerador rápido na previsão de radiação solar baseada em RNA para avaliação do potencial de recursos de energia solar de 76 locais no noroeste da Índia, foi a proposta dos pesquisadores (Yadav *et al.*, 2014).

Neste estudo, os autores trazem uma nova técnica o *Rapid Miner* que é usada para seleção de variáveis de entrada relevantes para previsão da radiação solar usando diferentes técnicas de RNA. Os modelos de RNA desenvolvidos com ferramenta de ajuste de redes neurais artificiais (*nftool*) apresentam melhores resultados que RBFNN e GRNN para predição de radiação solar. O erro percentual absoluto médio (MAPE) para ANN-1, ANN-2, ANN-3, ANN-4 e ANN-5 é 16,91, 16,89, 16,38, 6,89 e 9,04. O modelo ANN-5 utilizou variáveis de entrada mais acessíveis para que possa ser usado para prever a radiação solar para 41 locais de Gujarat e 35 locais de Rajasthan, no noroeste da Índia.

Em (2019), um sistema de mineração de dados para prever a irradiância espectral global solar, foi desenvolvido por (Campo-Ávila *et al.*, 2019), fazendo uma avaliação de desempenho nas faixas de resposta espectral de módulos fotovoltaicos de película fina. Os pesquisadores propõem uma metodologia baseada no uso de certas técnicas de classificação e regressão para

prever a distribuição espectral global da irradiância solar. Os modelos foram avaliados para diferentes faixas de comprimento de onda levando em consideração a resposta espectral de módulos fotovoltaicos de diferentes tecnologias. Os erros na previsão da irradiância espectral global solar para comprimentos de onda que variam entre 350 e 900 nm e massa de ar inferior a 2,1 são menores que 7% em dias de céu claro e que 16% para dias nublados.

Mineração de dados vinculativa e conhecimento especializado para previsão com um dia de antecedência da radiação solar global horária foi proposto por (Campo-Ávila *et al.*, 2021). A metodologia desenvolvida baseia-se na contribuição de diferentes especialistas para obter modelos melhorados baseados em dados quando incluídos no processo de mineração de dados. Como resultado do processo de aprendizagem automática, incluindo o conhecimento de diferentes especialistas, foram identificados 14 tipos diferentes de dia com base na forma da radiação solar horária ao longo do dia. Para a avaliação de desempenho, foi usada, a raiz do erro quadrático médio relativo do modelo de previsão que é inferior a 20%, o que significa uma redução significativa em comparação com modelos anteriores. Além disso, os modelos propostos podem ser reconhecidos no contexto da Inteligência Artificial.

2.3 MODELO DE CIRCUITO IDEAL

Em aprendizado de máquina, modelo de circuito ideal são representações teóricas que visam a simplificação dos circuitos usados com objetivo de simular o comportamento de redes neurais e algoritmos de aprendizado, tendo condições ideais para facilitar a compreensão das ideias essenciais.

Deste modo, a avaliação de modelos combinados de irradiância solar em superfícies inclinadas e previsão de geração de energia fotovoltaica foi feita pelos autores Cui *et al.* (2019) a proposta, traz como a abordagem, a predição física baseada na irradiância solar em superfícies inclinadas. O método proposto, seleciona três modelos de decomposição e quatro modelos de transposição para serem combinados em 12 modelos de previsão. Os resultados apresentados pelos pesquisadores, mostram que os métodos que combinam o modelo de transposição Liu-Jordan apresentam maior precisão de previsão sob os diferentes tipos de clima. Entre eles, destacam – se, as previsões do modelo Erbs + Liu-Jordan são as mais precisas.

No estudo de Shuvho *et al.* (2019) os autores avaliam a previsão de irradiação solar e avaliação de desempenho de usina solar fotovoltaica de 80KWp conectada à rede em Bangladesh. Neste estudo é apresentado um modelo de previsão de irradiação solar baseado em lógica fuzzy e redes neurais artificiais que visa alcançar uma boa precisão em diferentes

condições climáticas. Os mesmos concluíram que o desempenho da RNA é melhor que o modelo lógico fuzzy comparando RMSE e R^2 .

Foi desenvolvido pelos autores Chaibi *et al.* (2019) o modelo de previsão de potência e sua validação para uma usina fotovoltaica de cobertura considerando a degradação do módulo. Neste estudo, os autores fazem uso dos parâmetros da célula solar que são medidos usando um simulador “Sun classe A” para determinar a degradação fotovoltaica. O modelo com três parâmetros é mais preciso, com erro percentual absoluto médio mínimo de 3,7% sob faixa de baixa irradiância solar. Os resultados para os modelos de quatro e cinco parâmetros são mais precisos nas faixas de irradiância solar média (150 – 500 W/m²) e alta (>500 W/m²), com erro percentual absoluto médio de 5,4% e 4,21%, respectivamente. Os resultados obtidos pelos autores, revelam que no presente modelo, após incluir a degradação, pode prever com mais precisão a potência real de saída de um sistema fotovoltaico.

2.4 MODELO BASEADOS EM PROGRAMAÇÃO GENÉTICA MULTIGENE (PGMG)

Modelos baseados em programação genética multigene, em aprendizado de máquina entende-se como sendo técnica que utiliza múltiplos genes, também conhecidos como subprogramas, que compõe soluções complexas, o que permite abordagem evolutiva para a resolução de problemas de previsão, otimização, regressão e classificação.

Desta forma, no estudo de Khosravi *et al.* (2018), propuseram o uso de algoritmos de aprendizado de máquina para prever a radiação solar horária na Ilha de Abu Musa. Para o desenvolvimento dos modelos de previsão dois tipos de dados de entrada foram usados, os autores designaram os modelos de N1 e N2, sendo também, desenvolvidas redes neurais *feed-forward* multicamadas (MLFFNN), redes neurais de função de base radial (RBFNN), regressão vetorial de suporte (SVR), sistema de inferência fuzzy (FIS) e sistema de inferência neuro-fuzzy adaptativo (ANFIS). Os resultados demonstraram que para os modelos N1, SVR e MLFFNN apresentam desempenho máximo para prever a irradiância solar com $R = 0,9999$ e $0,9795$, respectivamente. Para os modelos N2, SVR, MLFFNN e ANFIS relataram o coeficiente de correlação superior a 0,95 para o conjunto de dados de teste.

A programação genética multigene (PGMG) foi usada por Citakoglu, Babayigit e Haktanir (2020) para a predição da radiação solar, na abordagem é proposta um novo método compacto para este fim, o mesmo é verificado para produzir estimativas mais precisas da radiação solar na Turquia. Dados meteorológicos como radiação solar extraterrestre, duração do sol, média das horas máximas ensolaradas mensais, média de longo prazo das temperaturas

máximas mensais do ar, média de longo prazo das temperaturas mínimas mensais do ar, temperatura média mensal do ar e dados mensais de umidade média são selecionados como entradas do modelo. Os autores concluíram que os modelos multi dados do *PGMG* ou *MGGP* e as equações empíricas calibradas são mais bem-sucedidos do que os modelos de dados únicos para predição da radiação solar.

Al-Hajj *et al.* (2021) desenvolveram um modelo híbrido para previsões diárias da radiação solar utilizando técnicas de programação genética. Neste estudo, os autores descrevem um modelo híbrido não linear baseado em modelos *Long Short-Term Memory* (LSTM) e na técnica de Programação Genética para previsão de curto prazo da radiação solar global (GSR). Estes modelos são usados como preditores básicos de GSR usando dados meteorológicos e de radiação solar (SR). Os autores demonstraram uma melhoria em termos de desempenho proporcionada pelo modelo híbrido proposto, tendo sido comparados seu desempenho com técnicas de empilhamento baseadas em aprendizado de máquina para combinação. Os resultados mostram que o método sugerido proporciona melhorias significativas em termos de desempenho e consistência.

2.5 MODELO BASEADOS EM RNA

Os modelos baseados em redes neurais artificiais caracterizam-se pela utilização de estrutura composta por neurônios artificiais interconectados que visam o processamento de informações e a realização de tarefas específicas por meio de ajustes de pesos sinápticos durante o treinamento. Os modelos de RNAs podem ser: perceptron simples; redes neurais feedforward (FFNN); redes neurais convolucionais (CNNs); redes neurais recorrentes (RNNs); redes neurais de memória (Memory Network); long short-term memory (LSTM); redes neurais generativas adversariais (GANs); redes neurais autoencoders, entre outros.

Dados geográficos como, latitude, longitude e altitude, e dados meteorológicos como umidade relativa, índice de clareza, temperatura média e a pressão, foram usados por Chiteka e Enweremadu (2016) para estudos de previsão de Irradiação Horizontal Global (GHI) em certas localidades no Zimbábue. A rede neural de *backpropagation multilayers* com algoritmo de otimização *Levenberg-Marquardt*. A rede contém sete entradas, uma camada oculta e uma camada de saída, tendo como objetivo uma variável de saída; a referida rede dispõe de dez neurônios usando tansig como função de transferência nas camadas de entrada e saída, esta foi considerada o melhor modelo preditivo dentre os avaliados tendo obtido um coeficiente de determinação (R^2) de 99,894%.

Um conjunto de redes neurais como a rede neural de *backpropagation feed-forward* (FFNN), rede neural de base radial (RBNN) e rede neural de regressão generalizada (GRNN), foram usadas por Kuhe, Achirgbenda e Agada (2018), com o objetivo principal de prever a radiação solar global média mensal de Makurdi – Nigéria, a fim de melhorar a precisão da previsão. Os dados de entrada foram médias mensais de temperatura máxima diária, temperatura mínima diária, umidade relativa diária, duração diária de insolação e velocidade do vento, tendo os autores obtidos os mesmos na estação meteorológica de (NIMET) Makurdi. Quanto ao desempenho, as redes neurais propostas previam a radiação solar com grande precisão; contudo, o conjunto de RNA, obteve melhores resultados implicando elevada dependência do modelo para avaliação da radiação solar nos locais onde os instrumentos de radiação solar não estão disponíveis ou apresentaram falhas.

Tendo como objetivo de treinar e desenvolver o melhor modelo de redes neurais artificiais (RNA) para previsão de radiação solar, os autores Heng *et al.* (2022), fizeram o uso da estação meteorológica de Kuala Terreganu – Malásia, para coletarem os dados meteorológicos, como a temperatura, umidade relativa, a velocidade do vento; como modelo de RNA para os estudos usaram diferentes algoritmos e dados meteorológicos para previsão de radiação solar, nos quais foram treinados três algoritmos diferentes, sendo *Levenberg-Marquardt*, gradiente conjugado escalonado e *bayesian regularization*, após a comparação dos resultados e tendo como métrica de avaliação de desempenho R^2 máximo 0,8113% e RMSE mínimo de 0,2581% para rede treinada pelo algoritmo regularização bayesiana, tendo alcançado o melhor desempenho.

2.6 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo, buscou-se entender os 4 modelos para compreender a correlação dos trabalhos com o modelo que se pretende desenvolver para prever a irradiância solar para Benguela e adequar para outras localidades de Angola, cujo objetivo visa otimizar a geração de energia fotovoltaica.

Importa realçar que a área de pesquisa de irradiância solar está em constante evolução por conta da alta demanda no setor energético. Apesar dos modelos apresentados e discutidos neste capítulo tenham demonstrado um desempenho promissor, há sempre espaços para melhorar e inovar.

Por tanto, se augura desenvolver um modelo que possa aprimorar ainda mais a precisão nas previsões e dessa forma elevar o desempenho na geração de energia fotovoltaica, para Benguela, Angola.

3 RADIAÇÃO SOLAR

3.1 INTRODUÇÃO

A energia emitida pelo sol que se propaga em todas as direções por meio de ondas eletromagnéticas é conhecida por radiação solar (Beer *et al.*, 2010). A radiação solar ao atingir a superfície terrestre diariamente acaba desempenhando uma função importante no balanço energético de vários processos físicos, químicos e biológicos (USA, 2013). Nas últimas décadas a radiação solar tornou-se a principal fonte de energia limpa (Miles, 2006), sendo que, as variações na quantidade de radiação solar acabam influenciando significativamente nos fluxos de calor sensível e oculto, o ciclo hidrológico, os ecossistemas terrestres e o clima (Meza; Varas, 2000).

A conversão da radiação solar em outras formas de energia como térmica e elétrica dependem da viabilidade operacional, técnica e econômica de uma determinada região. (USA, 2013). Uma vez que, a radiação atravessa a atmosfera e interage com seus elementos, ela sofre reflexão, difusão e absorção (Iqbal, 1983). Assim sendo, o processo de transmissão da radiação solar ou energia radiante, acaba sendo complexo devido ao número elevado de elementos que se apresentam na atmosfera bem como a sua influência. Importa realçar que as nuvens, são um dos elementos atmosféricos com rápida variação no tempo e que acaba tendo, um maior impacto sobre a radiação solar ao nível do solo (Echer *et al.*, 2006). Porém, a quantidade de nuvens conhecida como nebulosidade presentes na atmosfera em um determinado local, impacta de forma direta na quantidade de radiação que chega ao solo, levando a possibilidade de definir um “índice de claridade” K_t (Rensheng *et al.*, 2004).


Ao calcular este índice, leva-se em conta I_0 , que é a irradiância fora da atmosfera, também conhecida como radiação solar incidente ou irradiância extraterrestre. Assim, esta é considerada a média anual da irradiância extraterrestre, igual a 1367 W/m^2 , conforme expresso na equação (1). Onde, R_{mD} representa a distância média entre o Sol e a Terra, enquanto R_D é a distância real entre o Sol e a Terra, que varia dependendo do dia do ano (Benghanem, 2011).

$$I_0 = 1367(R_{mD}/R_D)^2 \quad (1)$$

3.2 IRRADIÂNCIA GLOBAL HORIZONTAL

A irradiância solar oferece dados importantes para o planejamento geração de energia fotovoltaica (Benghanem, 2011). Posto isto, define-se como irradiância global horizontal ao potencial total da radiação proveniente do sol que se expande por unidade de superfície horizontal (ou *Global Horizontal Irradiance – GHI*, do inglês) (Becerra-Rondon *et al.*, 2020). A GHI é dada pela combinação de dois elementos de I_0 : a Irradiância Normal Direta (DNI) e a Irradiância Horizontal Difusa (DHI) (Inman; Pedro; Coimbra, 2013). Além destes dois elementos, pode-se incluir a Irradiância Refletida no solo que incide na superfície, como ilustrada na Figura 1.

Figura 1 – Ilustração das componentes da irradiância global horizontal



Fonte: Monteiro *apud* Araújo (2012, p. 9).

A DNI citada por Inman, Pedro e Coimbra (2013) é a radiação que atinge perpendicularmente uma superfície ao nível do solo, enquanto que, a DHI se define como radiação que, apesar de dispersa na atmosfera, ainda alcança a superfície terrestre. A combinação dessas duas é expressa pela equação 2, onde θ é o ângulo zenital, que corresponde ao ângulo formado pelo sol e uma linha perpendicular à superfície (Benghanem, 2011). A quantidade de radiação solar que a terra absorve ou reflete é influenciada pelo ângulo zenital. Assim, para estimar o clima médio de um planeta em equilíbrio convectivo-radiativo, é necessário considerar a medida global da irradiância global horizontal e definir um ângulo zenital solar que seja constante ao longo do tempo ou que varie durante o dia, ou seja com o nascer e o pôr do sol (Benghanem, 2011).

$$GHI = \cos\theta \cdot DNI + DHI \quad (2)$$

As medições de irradiância são geralmente realizadas utilizando a unidade [W/m^2] do Sistema Internacional de Unidades (SI), pois representam uma quantidade de energia instantânea. Alguns pesquisadores também empregam essa unidade para representar energia em relação ao tempo [Wh/m^2] (Pedro Bon, 2020, p. 42).

Portanto, a compreensão da Irradiância Global Horizontal e seus componentes, tais como; a Irradiância Normal Direta e a Irradiância Horizontal Difusa, é crucial para a avaliação precisa do potencial solar de uma região. Esses elementos, quando medidos e analisados corretamente, podem fornecer informações valiosas para o planejamento e a otimização de sistemas de energia solar. A obtenção de valores da irradiância solar com alta precisão são importantes nos modelos climáticos e atmosféricos (Solanki; Krivova; Haigh, 2013).

3.3 IRRADIÂNCIA GLOBAL HORIZONTAL NA SUPERFÍCIE TERRESTRE

A energia solar que chega à superfície do nosso planeta é cerca de dez mil vezes maior do que a demanda energética mundial. Portanto, se conseguisse aproveitar apenas 0,01% dessa energia, poder-se-ia atender a todas as necessidades energéticas da humanidade (Águia, 2016, p.30). Apesar das suas particularidades geográficas, das sazonalidades, certa quantidade de radiação solar atinge um ponto específico ao chegar à terra, (USA, 2013). A porção de radiação incidente na terra que é refletida de acordo as características do solo é conhecida como albedo.

Entender o valor do albedo, dá uma ideia do grau de reflexão da radiação e da proporção entre a radiação direta e a difusa. Geralmente, um albedo maior indica uma maior reflexão solar e uma maior parcela de radiação difusa. A variação do albedo ocorre de 0 a 1 (Águia, 2016, p.33):

- Um valor de albedo de 0 é atribuído a um corpo negro, que absorve toda a radiação que nele incide.
- Albedos que variam de 0,1 a 0,2 são típicos de superfícies terrestres de cor escura.
- Superfícies lisas e de cor clara geralmente apresentam valores de albedo entre 0,4 e 0,5.

Segundo Veissid e Pereira (2000), aproximadamente 30% da radiação solar que atinge a Terra é refletida de volta ao espaço, essa porcentagem é conhecida como albedo planetário. Vale ressaltar que, a variação do albedo planetário ao longo do tempo é crucial para o acompanhamento das alterações climáticas globais. Isso ocorre porque a média da temperatura

atmosférica é, em última análise, controlada pelo equilíbrio energético global, que é a diferença entre a radiação solar que atinge o topo da atmosfera e a que é refletida de volta ao espaço (Veissid; Pereira, 2000).

Graças à forma geóide do nosso planeta, a luz solar atinge a superfície terrestre em ângulos que variam de 0° a 90° (USA, 2013). Quando os raios solares incidem verticalmente (90°) sobre a superfície, a área recebe a máxima quantidade de energia. O oposto também é verdadeiro (USA, 2013). Para Yadav e Chandel (2014), a declinação (δ), que varia de $-23,45^\circ$ a $23,45^\circ$, é o nome dado à posição angular do Sol no meio-dia solar. Por outro lado, a inclinação (β), que varia de 0° a 180° , é o termo usado para descrever o ângulo entre a superfície do plano e a linha horizontal (Yadav; Chandel, 2014).

Assim, quanto mais oblíquos são os raios solares, mais tempo eles levam para alcançar a Terra, tornando-se mais espalhados e difusos. É por isso que as áreas polares recebem menos luz solar (Yadav; Chandel, 2014).

Apesar das peculiaridades na disposição da radiação solar a nível da superfície terrestre, existem países que veem se destacando no fornecimento de energia elétrica desde a matriz de geração fotovoltaica, onde os índices de incidência de radiação são avaliados para se retirar o máximo proveito desta fonte de energia renovável.

Também é essencial compreender o passado e a atual interação dessas nações com as fontes de energia renováveis, bem como as estratégias e políticas implementadas para promover a adoção e o crescimento dessas fontes de energia (Pedro Bon, 2020, p. 46).

3.3.1 Irradiância global horizontal na África

Ocupando uma área com cerca de $30,3 \times 10^6 \text{ km}^2$, com uma abrangência de 6% da superfície terrestre, sendo 20% da área total da terra (Chakraborty *et al.*, 2014), torna este continente no segundo e mais populoso do mundo. A predominância do sol abundante, faz do continente africano ser apelidado por continente do sol” (Griffiths, 2013).

Assim, aferir de forma contínua e eficiente a irradiância solar por longo período de tempo, ajuda na transformação e uso mais eficaz da energia solar (Bamisile *et al.*, 2020). Neste estudo, para compreensão da disposição da GHI no continente africano Figura 2, fez-se a seleção de 11 países dos 54 existentes, sendo estes pertencentes a diferentes zonas geopolítica, Figura 3, sendo disposta a GHI ao longo do ano da seguinte forma:

Quadro 1 – Valores de GHI dos países selecionados segundo as divisões regionais

Regiões	Países	Valores em kWh/m²
África Setentrional	Argélia	1680 a 2410
	Egito	2045 a 2483
África Ocidental	Gana	1607 a 2211
	Nigéria	1534 a 2264
África central	Angola	1350 a 2070
	República centro Africana	1899 a 2264
	Chade	2118 a 2483
África Oriental	Etiópia	1753 a 2483
	Somália	1899 a 2483
África Meridional	Namíbia	2118 a 2447
	África do Sul	1534 a 2264

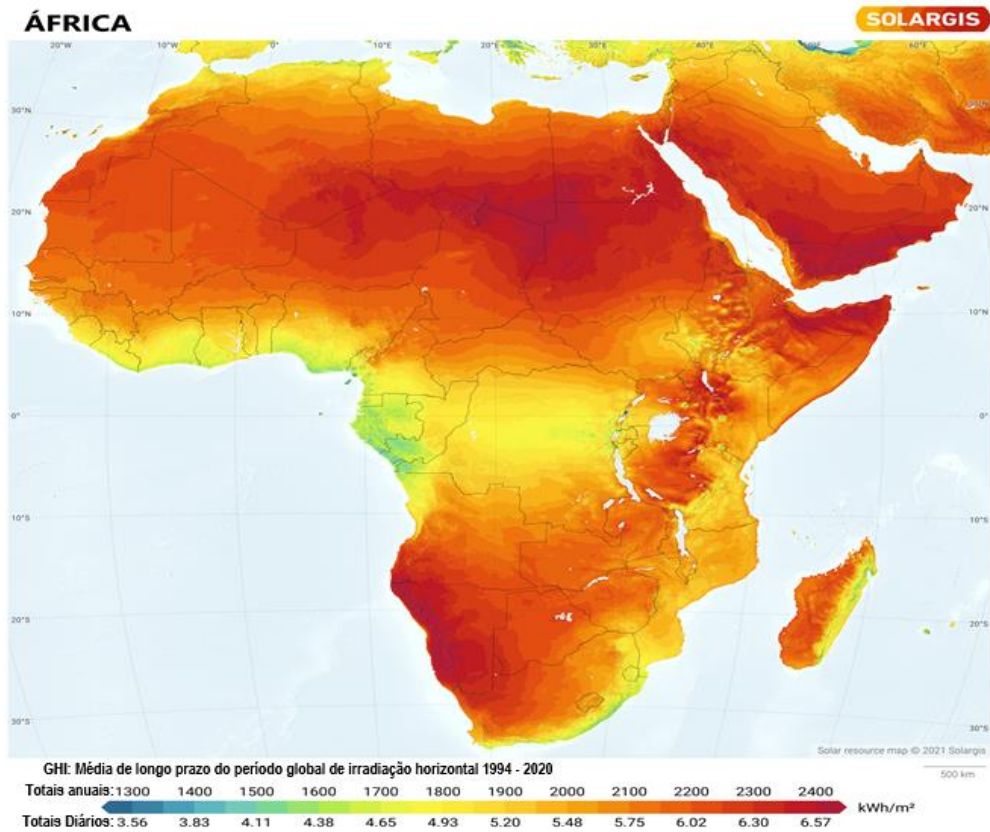
Fonte: adaptado de SOLARGIS (2020a).

Com os dados da Quadro 1, é possível perceber uma harmonia quase que uniforme na distribuição da energia solar sendo que a GHI alcança 85% maior da proporção da paisagem que acaba sendo superior a 2000 kWh/m²/ano (Baashar *et al.*, 2022).

O potencial de geração estimado de energia solar é de 1000 GW, que acaba não sendo explorados (Buckman *et al.*, 2018) por várias razões como, instabilidade e falta de políticas no setor energético, apesar disto, estima-se 60 x10⁶ TWh/ano de geração teórica ou ideal (Liu; Jordan, 1960). Contudo, a falta de materiais técnicos e boas infraestruturas, acabam inviabilizando a medição da radiação solar em países subdesenvolvidos (Benmouiza; Cheknane, 2019).

Não obstante, às dificuldades, estudos de previsões com elevado grau de precisão da irradiância global horizontal tem sido feito com mais frequência nesta região do continente, demonstrando a relevância para o plano energético (Mfetoum *et al.*, 2024).

Figura 2 – Mapa de África de irradiância global horizontal



Fonte: adaptado de SOLARGIS (2020a).

Figura 3 – Mapa de África com as divisões regionais, realçando países usados para o estudo



Fonte: adaptado de Lima (2006).

3.3.2 Impacto da irradiância global horizontal

3.3.2.1 Impacto da irradiância global horizontal no setor energético da África do Sul

O desenvolvimento industrial e econômico é diretamente proporcional ao consumo de energia (Gómez-Expósito; Conejo; Cañizares, 2018), no continente africano a lista de países mais industrializados é liderado pela África do Sul e o Egito (IRENA, 2022).

A presença abundante da luz solar na África do Sul tem a duração de mais de 2500 horas por ano, sendo que a sua radiação solar apresenta uma variação de 4,5 à 6,5 kWh/m² em um único dia, Figura 4, observa-se ainda, a radiação solar global no período de 24 horas de 220 W/m² que é maior do que a vista em a várias partes de alguns estados norte americano que apresentam, em média, 150 W/m² e, também, superior ao da União europeia com 100 W/m² (MORDOR INTELLIGENCE, 2024c). O mercado de energia renovável Sul africano, com particular realce ao de geração fotovoltaica, em 2021, teve uma capacidade instalada de 2,91 GW (IRENA; AfDB, 2022), nos dias que correm o sistema energético da África do Sul na sua capacidade instalada, conta com 50% de energias renováveis da mistura total.

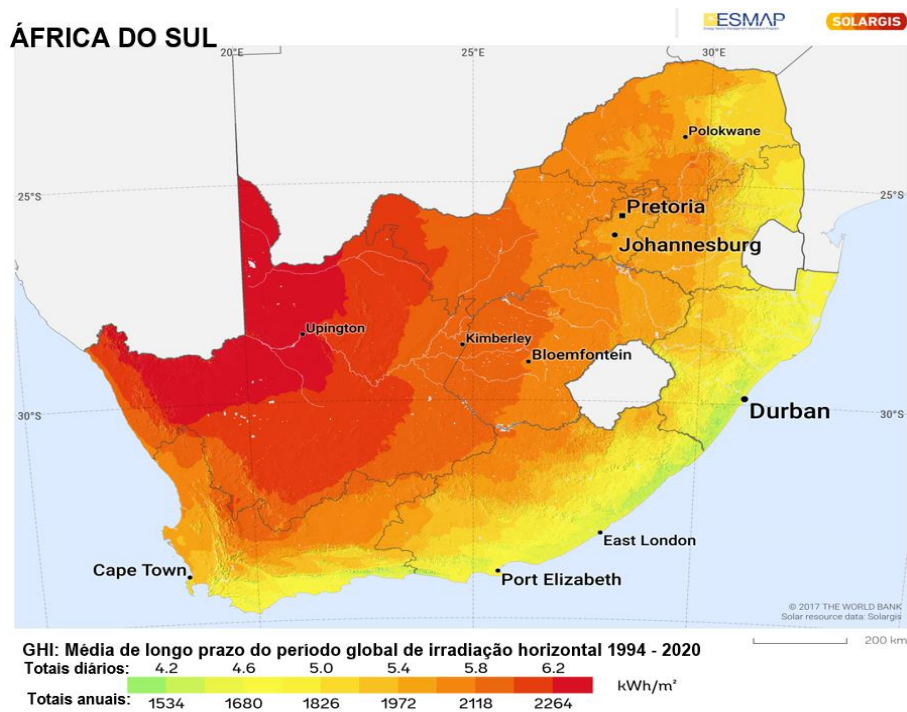
Esta façanha, tem atingido tal feito, graças a programas e políticas governamentais que apoiam e têm elevado o crescimento do setor das energias renováveis, onde o aproveitamento da GHI tem sido direcionado com propósitos de facilitar a acessibilidade à eletricidade, galvanizar o combate a descarbonização dos sistemas energéticos, alavancando o setor econômico, desta feita, elevar a segurança energética (MORDOR INTELLIGENCE, 2024c), das políticas implementadas, importa realçar o seguinte programa:

Programa Sul-africano de Aquisição de Produtores Independentes de Energia Renovável (REIPPPP) que acabou atraindo, em 2021, 13 bilhões de dólares, sendo capital privado que serviu para a construção e operacionalização de 77 instalações solares e eólicas (MORDOR INTELLIGENCE, 2024c). Já em fevereiro de 2022, com o projeto de energia solar concentrada (CSP) (do inglês *Concentrated Solar Power*) de *Redstone*, sendo uma central CSP integrada com a capacidade de 100MW, tendo garantido um financiamento na ordem dos 764,63 milhões de dólares, em março do mesmo ano, a *Amazon* inaugurou uma usina solar na província de Cabo Setentrional com uma capacidade de geração estimada em 28.000 MWh. No mesmo mês, assinalou-se a celebração de um contrato que culminou com a aquisição de energia de longo prazo com um produtor independente sendo esta a *SOLA Group* com o objetivo de

fornecer 200 MW de energia solar às minas e fundições da *Tronox*, a previsão da entrega deste projeto estava para os finais de 2023 (MORDOR INTELLIGENCE, 2024c).

Estudos sobre irradiância solar foram feitos com o objetivos de se aproveitar melhor este recurso natural, uma vez que o governo da África do Sul tem objetivos de até 2050 alcançar emissões líquidas zero, onde os projetos estão voltados para energias renováveis, com especial atenção a energia solar e eólica, sendo que neste país, adotaram dois métodos para aproveitamento da energia solar, sendo a energia solar concentrada e a fotovoltaica (AFRICAN UNION COMMISSION, 2023).

Figura 4 – Mapa de irradiância global horizontal na África do Sul



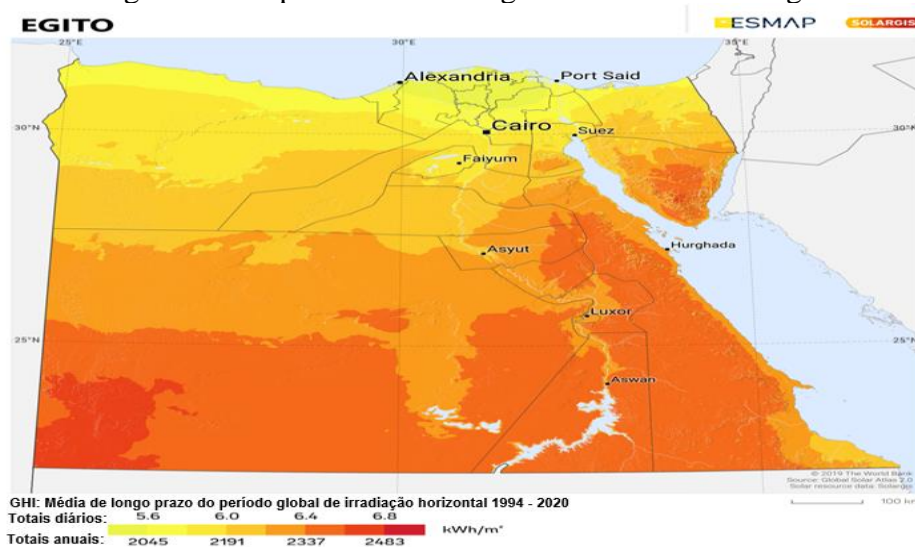
Fonte: adaptado de SOLARGIS (2020b).

3.3.2.2 Impacto da irradiância global horizontal no setor energético do Egito

O parque de usinas solares fotovoltaicas para a geração de eletricidade no Egito dispõe de alto potencial, pois se estende por todo país, colocando-o como a segunda potência industrial no continente (MORDOR INTELLIGENCE, 2024a). Dispondo de 1899 à 2775 kWh/m²/ano de radiação solar direta na Figura 5 pode ser observado a GHI, de 2045 à 2483 (SOLARGIS, 2020), que faz do Egito um pilar fundamental na geração de energia solar, sendo que do norte ao sul apresenta uma exposição solar diária de 9 à 11 horas, com pouca nebulosidade diária (IRENA, 2022). Estimado em 7,23 GW em 2024 e com previsão de crescimento de 10,67 GW

até 2029 (MORDOR INTELLIGENCE, 2024a), o mercado de energia renovável egípcio, continua a demonstrar crescimento significativo em 8,09% CAGR (*Compound Annual Growth Rate* que em português significa, Taxa de Crescimento Anual Composta) no período estabelecido. No final de 2020, apesar das suspensões de exportações e trabalhos temporários, o fornecimento de eletricidade proveniente de energia solar fotovoltaica foi planejado para atingir 22% com uma concentração de energia solar (CSP do inglês, *Concentrated Solar Power*) de 3% (IRENA; FAO, 2021). Para o alcance das metas estabelecidas, o governo egípcio, por meio do Ministério das Energias Elétricas e Renováveis, alterou o processo de licitação para projetos solares fotovoltaicos e eólicos em grande escala, com a pretensão de impulsionar o mercado energético (MORDOR INTELLIGENCE, 2024a). Além desta plataforma, para atração de investidores, existe a Estratégia Integrada de Energia Sustentável para 2035, que visa a instalação de 31.000 MW de energia solar até o referido ano.

Figura 5 – Mapa de irradiância global horizontal do Egito



Fonte: adaptado de SOLARGIS (2020d).

O *Benbam Solar Park*, que configura na lista dos maiores projetos tendo a capacidade de geração de 1465 MW, inaugurado em novembro de 2019, catapultou o Egito a figurar como um grande na geração de energia solar e vincar o seu objetivo de gerar eletricidade a partir de fontes renováveis para 20% ao ano de 2022 (IEA, 2021). Por outro lado, as políticas implementadas pelo governo egípcio, conseguiram atrair grandes multinacionais como Siemens Gamesa, a Toyota Tsusho e outras que alavancaram o crescimento do setor, assim como, reduziram os custos de energia no país, desenvolvendo o mercado energético local e tornando-o mais competitivo (MORDOR INTELLIGENCE, 2024a). Para melhor responder a produção

que é intrinsicamente ligada ao consumo, visando apoiar medidas nas energias renováveis e na melhoria da eficiência energética, os governos da Alemanha e do Egito, criaram o comitê misto Egípcio-alemão (MORDOR INTELLIGENCE, 2024a).

O governo Egípcio continua a impulsionar e financiar estudos para melhorar o aproveitamento da GHI disponível no seu território, criando políticas e mecanismos como o caso da Engenharia, Aquisição e Construção (EPC do inglês *Engineering, Procurement, and Construction*).

Trata-se de um tipo de contrato de construção usado em grandes projetos que para a caso concreto em energia renovável para construção de infraestrutura de grande envergadura, *Build-Own-Operate* (BOO para o português Construir, possuir e operar) e *feed-in-tariffs* (FITs para o português Tarifas para ligação) que aumenta a atração de investidores privados para que o investimento estrangeiro direto reflita no mercado local (MORDOR INTELLIGENCE, 2024b) e assim alavancar o crescimento econômico e o desenvolvimento industrial.

3.3.2.3 Impacto da Irradiância global horizontal no setor energético de Angola

A estruturação legal do setor elétrico teve o seu marco inicial em 1996, com ênfase da publicação da Lei Geral da Eletricidade, tendo sido aprovada pela Lei nº 14-A/96, de 31 de maio, a referida lei associava à Política de Segurança energética de Angola de 2011, que serviu de acesso para promulgação de vários novos regulamentos fundamentais para o mercado de energia e consequentemente levou a alteração da Lei Geral da Eletricidade.

Importa ressaltar o decreto presidencial nº 76/26 – pagina 2 (2021): Lei Geral da Eletricidade, que estabelece o regime jurídico aplicável ao exercício das atividades de produção, transporte, distribuição e comercialização de energia elétrica, bem como, estabelece as bases de concessão de produção, transporte e distribuição de energia (Angola, 2021).

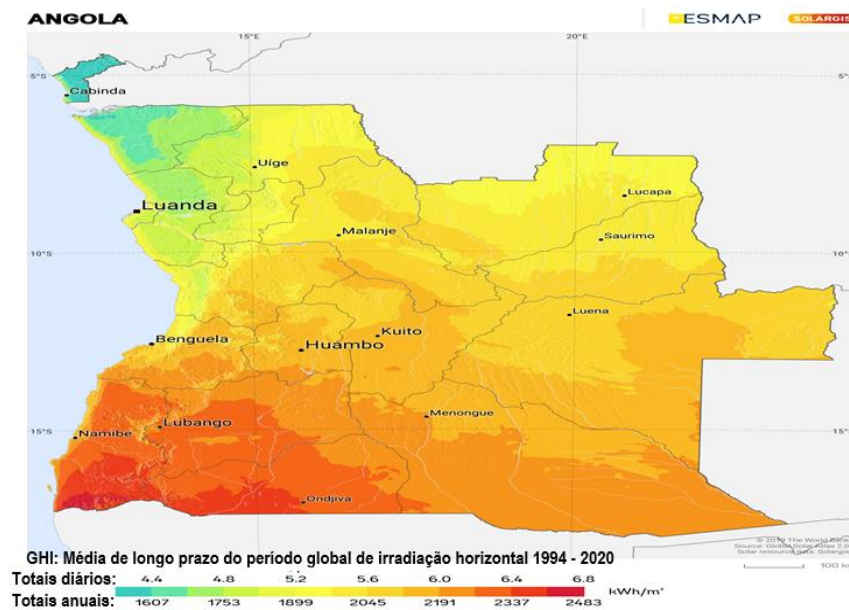
Com uma população atualmente estimada em cerca de 33 milhões de habitantes, e 46,9% com acessibilidade à energia elétrica (WORLD BANK, 2022), o território angolano, apresenta uma radiação global em plano horizontal correspondente a 1350 à 2070 kWh/m²/ano e com uma irradiância global horizontal 1607 à 2483 kWh/m²/ano (SOLARGIS, 2020c), como se ilustra na Figura 6. Os dados acima colocam a Angola em uma condição privilegiada, apresentando um território com elevado potencial de recurso solar, com baixa variação de disponibilidade deste recurso energético ao longo do ano. A intensificação da GHI se acentua nas províncias do centro e do Sul do país, e dispõe de enormes planícies, propício para a implementação de projetos de energia solar (Angola, 2014). Estimado em 17,3 GW o total do

potencial de geração de energia solar de todo país, os mesmos estão repartidos em 368 projetos, fazendo deste o maior recurso energético renovável que apresenta uma distribuição com maior uniformidade (Angola, 2014).

Os 27 anos de guerras vividos no país no período de 1975 à 2002, contribuiu para uma não eletrificação efetiva pois, danificaram os sistemas de transmissão e distribuição, olhando para este cenário que aumenta no já existente baixo índice de eletrificação do país, o que estimula um aumento na procura pela eletricidade cada vez mais necessária para o desenvolvimento social e econômico.

Deste modo, a energia solar torna-se um recurso ideal para contribuir na melhoria da eletrificação do país, apesar do baixo valor das energias renováveis na matriz energética (Angola, 2014). Assim, o baixo índice de eletrificação do país, cria um campo de oportunidades para investimento em energia renovável, bem como da sua tecnologia, cujo objetivo visa satisfazer o crescente consumo.

Figura 6 – Mapa de irradiância global horizontal de Angola



Fonte: adaptado de SOLARGIS (2020c).

Para melhor aproveitar e atrair investidor no mercado energético local e concomitantemente responder a demanda, surge o decreto presidencial nº 43/21- página 1 (2021): Regulamento de produção independente de energia elétrica, cujo objetivo no seu “artigo 1.º. o presente regulamento estabelece o regime jurídico aplicável à produção independente de

eletricidade e as regras sobre a aquisição do seu excedente para o abastecimento público” (Angola, 2021).

Este decreto, este último decreto, incentiva a produção independente das energias renováveis dando abertura a novos investidores e, por sua vez,, impulsionou o governo a dar início da implementação do projeto de construção das sete centrais fotovoltaicas, nas províncias de Benguela, Bié, Huambo, Moxico, Lunda Sul e Lunda Norte que, com as mesmas, pretende-se gerar cerca de 370 MW, sendo as centrais do Biópio e Baia - Farta em Benguelas foram as primeiras a serem erguidas, desde julho de 2022, marcando o passo na reestruturação da matriz energética, uma vez que a central fotovoltaica do Biópio com 188 MW e a da Baia – Farta com cerca de 96 MW totalizam 284 MW de capacidade de geração, contribuindo com aproximadamente 3,8%, no sistema elétrico público (Mbinza, 2023), com uma redução de cerca de 900.000 toneladas de CO₂, um valor considerável no impacto ambiental (Pascoal, 2021).

Estudos sobre irradiação solar ou potencial solar em Angola tem sido feitos e apoiados, uma vez que os dados de radiação global de 8 estações meteorológicas que são disponibilizados pela *World Radition Data Center* (WRDC), servindo-se de 4 estações de medição do Namibe para complementar as informações que regularmente são disponibilizadas pelo ministério de energias e águas do país (Angola, 2014).

3.4 FATORES QUE INFLUENCIAM NA PREVISÃO DE IRRADIÂNCIA GLOBAL HORIZONTAL

A previsão da irradiância solar na superfície da terra é o primeiro elemento que se leva em conta quando se quer prever a energia solar fotovoltaica para qualquer sistema (Jia *et al.*, 2021). A previsão de irradiância global horizontal, varia de acordo com a localização geográfica, pois a posição do sol em relação à terra tem impacto fundamental, como é caso das regiões próximas a linha do equador. Ademais, a altitude, o clima e a topografia são fatores que influenciam na quantidade de GHI que uma área recebe ou venha a receber (Caldas; Alonso-Suárez, 2019). Nesta pesquisa, são usadas como variáveis de entrada para a previsão de GHI os elementos climáticos, sendo eles, a temperatura, umidade relativa, pressão atmosférica, e a velocidade do vento. Segundo Caldas e Alonso-Suárez (2019), são os principais fatores que causam alterações bruscas na previsão de curto prazo da GHI.

3.4.1 Influência da temperatura atmosférica

Temperatura atmosférica é a medida da energia cinética média das moléculas do ar e é influenciada por diversos fatores climáticos e geográficos (Ahrens; Henson, 2015). Assim, a temperatura atmosférica, caracteriza-se por ser um dos principais parâmetros meteorológicos utilizados para o entendimento e previsão do clima. Conforme Iqbal (1983), as variações de temperatura na atmosfera podem alterar a quantidade de vapor de água e outros gases, o que, por sua vez, influencia a absorção e a dispersão da radiação solar, impactando, em última análise, nas previsões do GHI.

Assim sendo, a influência da temperatura atmosférica na radiação solar é multifacetada, envolvendo alterações na concentração de vapor d'água e outros gases de efeito estufa. As previsões precisas do GHI devem levar em conta essas variações induzidas pela temperatura (Badescu, 2008).

3.4.2 Influência da umidade relativa do ar

Segundo Allard e Feng (2018), define a umidade relativa do ar como sendo a razão, expressa em porcentagem, entre a quantidade de vapor d'água presente no ar e a quantidade máxima de vapor d'água que o ar pode conter a uma determinada temperatura. Assim, na previsão de GHI a umidade relativa do ar tem a sua influência pois dela depende a quantidade de vapor de água na atmosfera, afetando a transmissão da radiação solar, uma vez que a GHI é descrita como sendo a potência da radiação recebida por unidade de área horizontal na superfície terrestre.

Desta forma, compreende-se que quanto maior for a umidade relativa, maior será a quantidade de vapor de água no ar, o que pode levar a absorção bem como a dispersão da radiação solar, levando a redução da GHI. Não obstante, a umidade relativa alta acaba sendo relacionada à formação de nuvens, que refletem e bloqueiam a radiação solar, diminuindo consideravelmente o GHI.

3.4.3 Influência da pressão atmosférica

A pressão do ar atmosférico é um dos vários fatores meteorológicos que exercem sua influência na previsão da GHI (Sigauke; Chandiwana; Bere, 2022). Assim, a pressão do ar atmosférico pode afetar a densidade e a capacidade de absorção de GHI na atmosfera. Quando

a pressão do ar aumenta, a densidade do ar também aumenta, o que pode aumentar a quantidade de radiação solar dispersa e absorvida pela atmosfera, podendo resultar em uma diminuição na GHI. Além disso, a pressão do ar atmosférico pode influenciar a formação de nuvens. Mudanças na pressão atmosférica alteram a densidade do ar e, conseqüentemente, o percurso da radiação solar através da atmosfera, o que impacta a quantidade de irradiância solar que atinge a superfície (Iqbal, 1983).

Portanto, a influência da pressão atmosférica na radiação solar é frequentemente subestimada, mas desempenha um papel crucial na previsão precisa do GHI. Variações na pressão podem afetar a transmissão da radiação solar através da atmosfera (Sigauke; Chandiwana; Bere, 2022).

3.4.4 Influência da velocidade do vento

Para Wallace e Hobbs (2006) a velocidade do vento é a taxa de movimento do ar em relação à superfície terrestre. Trata-se de um parâmetro meteorológico importante pois influencia diversos processos naturais, atividades humanas e na geração de energia de fontes renováveis, sendo comumente expressa em metros por segundo (m/s). De acordo com Ahrens (2011), a ligação entre a irradiância solar e o vento é um tema de interesse na área das energias renováveis, uma vez que os dados do vento têm provado ser preditores eficazes da energia solar, sendo indicadores do movimento das nuvens e das condições atmosféricas.

A influência da velocidade do vento na previsão de GHI, pode ser notada de diversas formas, sendo, as mais comuns; a dispersão de nuvens e partículas na atmosfera, podendo contribuir no aumento da quantidade de partículas solares que atingem a superfície da terra; distribuição de aerossóis bem como da poeira, afetando a nitidez da clareza do céu, tendo como consequência direta a GHI (Østergaard *et al.*, 2022).

Assim, a velocidade do vento desempenha um papel crucial na previsão de GHI, influenciando a dispersão de nuvens e partículas na atmosfera, o que pode ampliar a transmissão de radiação solar e, por conseguinte, os níveis de irradiância solar recebidos na superfície terrestre (Østergaard *et al.*, 2022).

3.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo, procura-se levar ao entendimento inicialmente conceitual de uma das palavras que norteiam o estudo em causa, a radiação solar. Sendo a Irradiância Global

Horizontal (GHI), um quantificador da radiação solar direta e difusa recebida numa superfície horizontal, e de particular interesse para os sistemas de geração fotovoltaicos. Desta forma, realizou-se um estudo para aferir os níveis de GHI no continente africano de acordo com as divisões regionais selecionadas para o estudo, fez-se também uma comparação da GHI entre os dois países mais industrializados do continente, caso da África do Sul e do Egito para entender os caminhos que Angola deve seguir para alcançar a autossuficiência energética.

Por fim, procurou-se compreender os fatores meteorológicos que têm influência direta na previsão precisa da GHI, sendo estes usados como variáveis de entrada para o modelo proposto.

4 REDES NEURAIS ARTIFICIAIS

4.1 INTRODUÇÃO


De acordo com Haykin (2009), as RNAs podem ser vistas como conjuntos de unidades de processamento, representadas por neurônios artificiais interligados por um grande número de sinapses artificiais. O autor estende a sua definição analogamente ao cérebro, como sendo “modelos computacionais inspirados no sistema nervoso dos seres vivos, dotadas de capacidade de aquisição e manutenção do conhecimento baseado em informações”. Em termos simples, o funcionamento básico do cérebro envolve neurônios que ativam ou inibem o disparo de outros neurônios (Haykin, 2009). Assim, a estrutura dos neurônios, suas conexões e seu comportamento coletivo formam a base do estudo das redes neurais artificiais, que acabam se assemelhando ao cérebro humano de duas formas: (i) A rede adquire conhecimento do ambiente por meio de aprendizagem, (ii) Os pesos sinápticos entre neurônios armazenam o conhecimento adquirido (Haykin, 2009).

As RNAs, cada vez mais sofisticadas, são capazes de aprender a generalização de padrões complexos a partir de dados, adaptando-se a novas informações e situações (Haykin, 1999). Além disso, as RNAs são portadoras de capacidades como a auto-organização, mecanismos de associação e ajustam as conexões internas otimizando o desempenho. Sendo capazes de adaptar-se a novas realidades ou tendências, fazendo com que o poder de aprendizado e adaptação destas ferramentas, se tornam valiosas para resolver problemas complexos como a previsão de series temporais, reconhecimento de padrões, e o controle de sistemas complexos (Haykin, 2009). Para a previsão de energia solar a técnica de aprendizado de máquina que mais se recorre para o seu emprego são as RNAs (Antonanzas *et al.*, 2016).

4.2 NEURÔNIOS ARTIFICIAIS

A inteligência artificial tem nos neurônios artificiais também conhecidos como unidade de processamento, que busca simular o funcionamento de um neurônio biológico, sendo estes responsáveis da base estrutural, eles definem o funcionamento das redes neurais, dando-lhes capacidades de generalização, aprendizagem e resolução de problemas complexos. Segundo Kaminski Junior (2020), neurônios biológicos são as células básicas do cérebro humano, que se conectam formando uma rede sólida responsável por orientar as atividades do organismo e por todo o processamento e armazenamento de informações, conforme a Figura 7.

Figura 7 – Estrutura comparativa de um neurônio biológico e artificial



Fonte: Fernandes (2009).

De acordo com Haykin (2009), um modelo neural pode ser descrito por três elementos básicos:

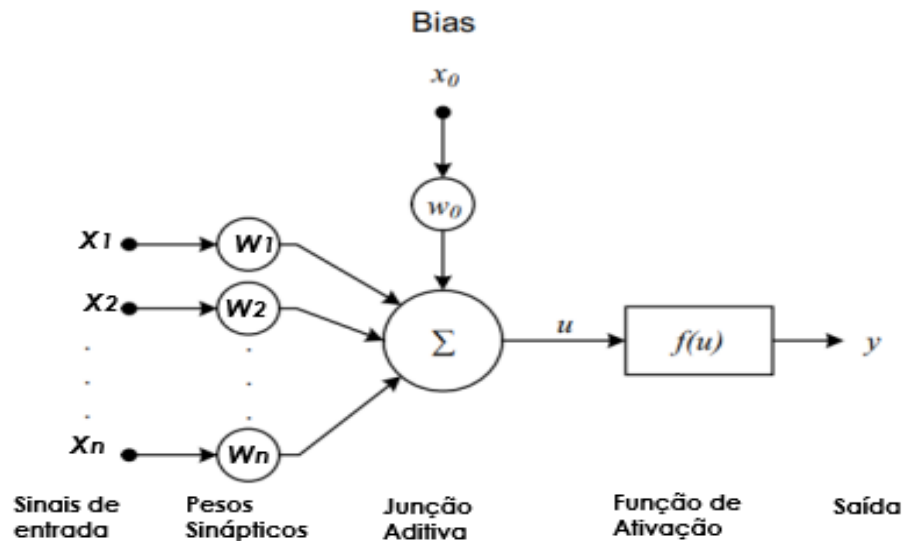
I. Um conjunto de sinapses (ou conexões), onde cada uma é caracterizada por um peso ou força específica. Os valores ($x_1, x_2, x_3, \dots, x_n$), representam os sinais de entrada nas sinapses, que são multiplicados pelos pesos sinápticos correspondentes ($w_1, w_2, w_3, \dots, w_n$). Esses pesos podem ser tanto positivos quanto negativos.

II. Um somador (Σ), cuja função é agregar os sinais de entrada ponderados pelos respectivos pesos sinápticos do neurônio. O *bias* tem a função de aumentar ou diminuir a entrada da função de ativação dependendo se ele é positivo ou negativo.

III. Uma função de ativação $f(u)$, que limita a amplitude da saída do neurônio. Esta função, também chamada de função restritiva, restringe o intervalo permitido da amplitude do sinal de saída a um valor finito. O intervalo normalizado da amplitude de saída de um neurônio pode ser um intervalo unitário fechado $[0,1]$ ou, alternativamente, $[-1,1]$.

Segundo Haykin (2009), os neurônios artificiais utilizados em redes neurais são não lineares, possibilitam saídas contínuas e executam funções simples. A representação dos neurônios proposta por McCulloch E Pitts (1943) é apresentada na Figura 8. Nesta proposta, os neurônios incorporam paralelismo e conectividade, características vinculadas a rede neural biológica (Haykin, 2009).

Figura 8 – Ilustração de um modelo não-linear de um neurônio



Fonte: adaptado de Haykin (2009).

Haykin (2009) realça que a função de ativação, $f(u)$, é responsável por gerar a saída y do neurônio a partir do vetor u , que é influenciado pelos vetores de peso $w = (w_1, w_2, \dots, w_n)$, de entrada $x = (x_1, x_2, \dots, x_n)$ e pelo *bias* associado. Na Figura 8, cada entrada x_n é ponderada por um peso sináptico w_n , pois trata-se de uma função degrau. Se a soma ponderada das entradas exceder o valor de *bias*, o neurônio é “ativado” e emite um pulso na saída; caso contrário, o neurônio não é “ativado”. O peso *bias* pondera uma entrada $x_0 = +1$, funcionando como um controle do nível de saída do neurônio. Desta forma, na Equação (3), fornece, a saída intermediária do neurônio (Haykin, 2009).

$$u = \left(\sum_{i=0}^n x_i \cdot w_i \right) \quad (3)$$

Sendo: u ; saída do somador, x_i ; entrada do neurônio e w_i ; peso sináptico de correspondente à entrada.

4.2.1 Função de ativação


A função de ativação é um componente fundamental, responsável pela definição da saída de um neurônio (Haykin, 1999). Para a rede neural as funções de ativação são fundamentais, uma vez que convertem a soma ponderada das entradas em uma saída que pode ser transmitida para a próxima camada de neurônios.

Existem vários tipos de funções de ativação, sendo as três mais utilizadas, a função degrau, a função linear e a função sigmoide (Hagan; Menhaj, 1994; Haykin, 1999).

A função degrau é uma função de ativação que retorna um valor fixo (geralmente 0 ou 1) dependendo se a entrada é menor ou maior que um determinado limiar (Haykin, 1999) conforme a Equação 4. Segundo Hagan e Menhaj (1994), a função degrau é utilizada em neurônios para classificar as entradas em duas categorias diferentes, na Figura 9, ilustra-se a função degrau d.

$$F(x) = \begin{cases} 0, & \text{se } x < 0 \\ 1, & \text{se } x \geq 0 \end{cases} \quad (4)$$

Figura 9 – Ilustração gráfica função degrau com variação de [1; -1]




Fonte: adaptado de Fernandes (2009).

Função linear é uma função de ativação que gera uma saída que é proporcional à entrada (Haykin, 1999). Esta função de ativação, limita a modelação de não linearidade, o que reduz a capacidade da rede neural de aprender padrões complexos. A Equação 5, faz compreender a referida limitação e na Figura 10 a ilustração da função linear.

$$F(x) = ax \quad (5)$$

Sendo que: a é o coeficiente de inclinação ou constante de proporcionalidade

Figura 10 – Ilustração gráfica da função linear




Fonte: adaptado de Fernandes (2009).

Função sigmoide, também designada por logística ou *logsig*, é uma função não linear que se parece com um “s” conforme Figura 11, ela mapeia a entrada em um intervalo entre 0 e 1, é também considerada uma função literalmente progressista com uma harmonização adequada entre um comportamento linear e não linear (Haykin, 1999). A Equação 6 representa a função sigmoide. Para a construção de redes neurais artificiais é recorrente o uso da função sigmoide (Haykin, 1999), com particular realce, em redes de múltiplas camadas com treinamento utilizando o algoritmo de *backpropagation* (Hagan; Menhaj, 1994).

$$F(x) = \frac{1}{1+e^{-\beta \cdot x}} \quad (6)$$

Sendo que: β é uma constante real que define a inclinação da função no ponto de inflexão e x é o valor de ativação do neurônio.

Figura 11 – Ilustração gráfica da função sigmoide



Fonte: adaptado de Fernandes (2009).

De acordo com Braga, Ludermir e Carvalho (2007), neurônios individuais dispõem de uma capacidade computacional limitada, independentemente da função de ativação escolhida. Portanto, um conjunto de neurônios interconectados, conforme a arquitetura de uma rede neural, é capaz de resolver problemas de alta complexidade.

4.2.2 Arquitetura das RNAs

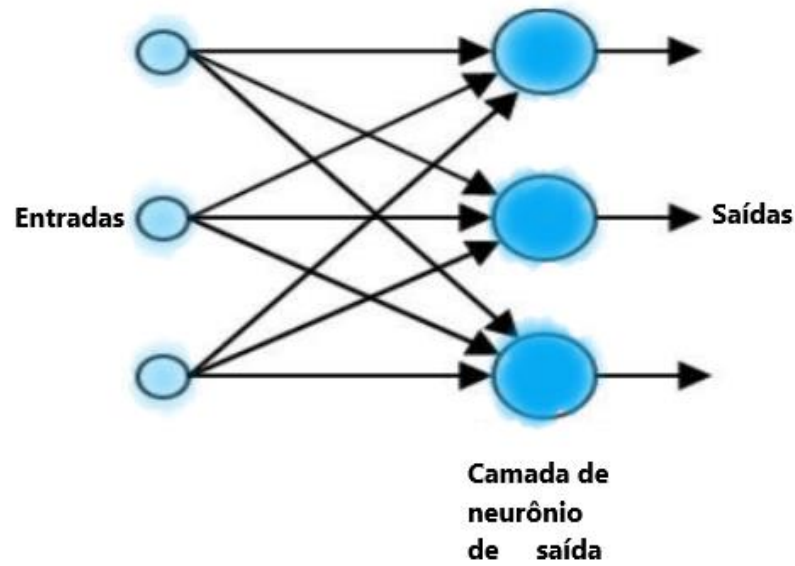
Segundo Hagan e Menhaj (1994), o uso de um único neurônio na resolução de problemas pode não fornecer a resposta desejada. Por isso, geralmente são utilizados vários neurônios em paralelo, formando uma estrutura denominada camada. A organização dessas camadas em uma RNA é conhecida como arquitetura de rede ou topologia de rede (Haykin, 1999). Assim, de acordo com Haykin (2009), o número de camadas, a quantidade de neurônios em cada camada, o tipo de conexão entre os neurônios e a arquitetura da rede são parâmetros que definem a topologia de uma rede.

Conforme Haykin (2009), a estruturação dos neurônios em uma rede está intimamente relacionada ao algoritmo de aprendizagem utilizado para treiná-la. As RNAs podem ser classificadas em dois tipos: recorrentes (*feedback*) e não-recorrentes (*feedforward*). As redes recorrentes possuem laços de realimentação, onde a saída de um neurônio em uma camada i é usada como entrada para um neurônio em camadas com índice menor ou igual a i (Haykin, 2009).

Em contraste, as redes não-recorrentes não têm laços de realimentação, de modo que cada neurônio recebe sinais apenas das camadas anteriores (Haykin, 2009). Outrossim, as RNAs não-recorrentes podem ter uma única camada ou múltiplas camadas, sendo que, no caso das múltiplas camadas, elas incluem as chamadas camadas ocultas (*hidden layers*). As RNAs que possuem mais de uma camada oculta são chamadas de *Perceptrons* de Múltiplas Camadas (*Multilayer Perceptrons* – MLP) (Haykin, 2009). Contudo, e de acordo com Haykin (2009), existem três principais tipos de arquiteturas de rede que são fundamentalmente diferentes:

a) Redes alimentadas adiante com única camada, como ilustrada pela Figura 12, nesse tipo de rede, os neurônios estão organizados em camadas, sendo que, na forma mais simples, há uma camada de entrada que se projeta diretamente sobre uma camada de saída de neurônios. Esta rede é estritamente do tipo alimentada adiante (*feedforward*).

Figura 12 – Rede *feedforward* de uma única camada de neurônios de saída

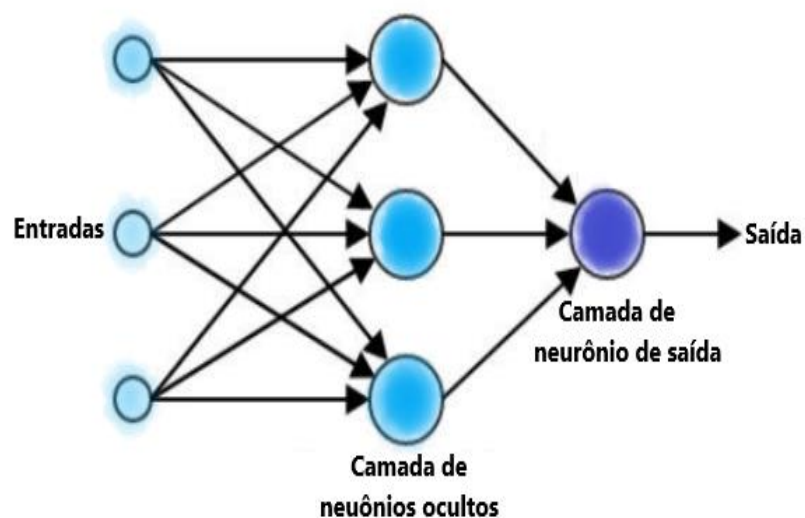


Fonte: adaptado de Haykin (2009).

b) Redes alimentadas adiante com múltiplas camadas (*feedforward* MLP)

Esta classe de rede neural, distingue-se pela presença de uma ou mais camadas ocultas. A adição de camadas ocultas permite que a rede extraia estatísticas de ordem superior. Essa capacidade é especialmente valiosa quando a camada de entrada é grande, conforme ilustrado na Figura 13.

Figura 13 – Rede *feedforward* com uma única camada oculta de neurônios

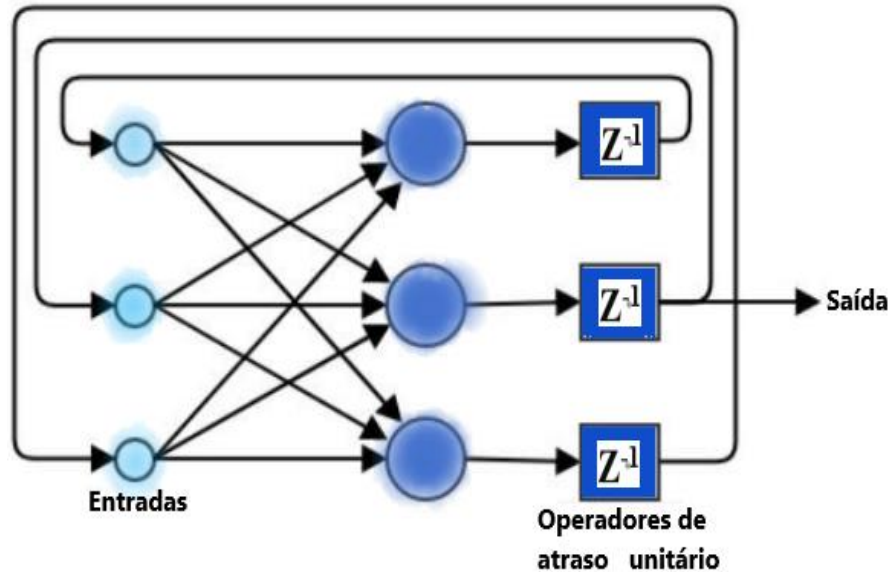


Fonte: adaptado de Haykin (2009).

c) Redes recorrentes

Uma rede neural recorrente, se diferencia de uma rede neural alimentada adiante pela presença de pelo menos um laço de realimentação. Essa rede pode conter neurônios ocultos ou não, como ilustrada na Figura 14.

Figura 14 – Rede recorrente com neurônios ocultos



Fonte: adaptado de Haykin (2009).

Existem diversas arquiteturas de redes neurais, mas a principal forma de classificação é baseada no número de camadas ocultas, distinguindo entre *perceptrons* de camada única e *perceptrons* de múltiplas camadas. Portanto, as redes neurais artificiais *multilayer perceptrons* (MLPs) são amplamente utilizadas na previsão de irradiância global horizontal (GHI) devido a várias razões que se fundamentam na sua flexibilidade, capacidade de modelagem não linear, e eficácia comprovada em diversas aplicações de previsão (Diagne *et al.*, 2013; Mellit; Pavan; Lughi, 2014; Voyant *et al.*, 2017).

Vale ressaltar que, além da arquitetura, uma das características mais importantes das redes neurais artificiais é a fase de aprendizagem, ou seja, a capacidade da rede de aprender a partir de exemplos (Capo, 2018).

4.2.3 Aprendizagem das RNAs

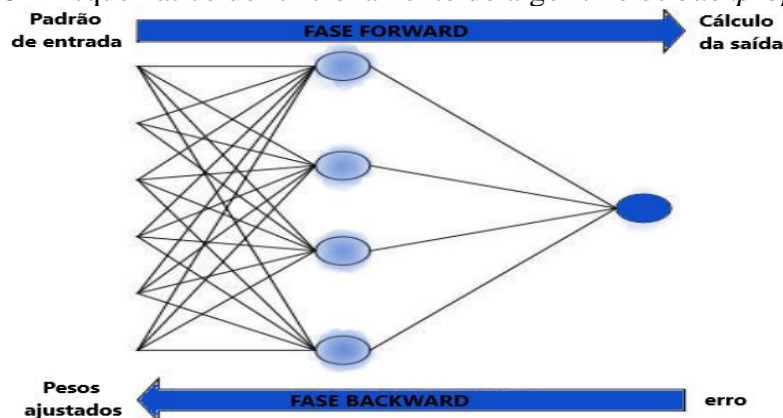
As redes neurais artificiais dispõem de uma característica fundamental que é a sua habilidade de aprender sobre o ambiente em que são implementadas e aprimorar seu

desempenho por meio do processo de aprendizagem (Haykin, 1999). O ajuste dos pesos sinápticos é conhecido como algoritmo de treinamento, que pode ser classificado em treinamento supervisionado ou não supervisionado (Haykin, 2009).

Durante o processo de treinamento supervisionado, a rede é treinada utilizando combinações de padrões de entrada e saída. Nesse modelo, um agente externo (professor) monitora o processo de aprendizagem, verificando se o comportamento da rede está de acordo com as entradas (Haykin, 2009). Assim, o treinamento supervisionado, é um problema de otimização no ajuste dos pesos sinápticos e requer que o conjunto de dados seja apresentado à rede várias vezes até que o erro seja satisfatório (Moriggi; Loh; Marques, 2020); considera-se um erro satisfatório quando atende aos critérios específicos definidos para o problema em estudo. Nesse tipo de treinamento, a rede recebe um conjunto de informações sobre o ambiente e a resposta desejada. A diferença entre a resposta desejada e a resposta obtida (erro) orienta o ajuste dos pesos sinápticos para minimizá-lo. O algoritmo de *backpropagation* (retropropagação) e suas variações são os métodos de treinamento supervisionado mais utilizados (Haykin, 2009).

Conforme Haykin (2009), O algoritmo de *backpropagation* utiliza pares de entrada e saída para ajustar os pesos da rede por meio de um mecanismo de correção de erros. O treinamento ocorre em duas fases, cada uma percorrendo a rede em um sentido. Essas fases são chamadas de fase *forward* e fase *backward*. A fase *forward* é utilizada para determinar a saída da rede para um dado padrão de entrada. A fase *backward* usa a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões. Na Figura 15 ilustra-se o funcionamento esquemático do algoritmo de *backpropagation*.

Figura 15 – Esquemático do funcionamento do algoritmo de *backpropagation*



Fonte: Teixeira Junior *et al.* (2012).

Os algoritmos de aprendizado baseados no algoritmo *backpropagation*, acabam sendo utilizados para acelerar a convergência (MANTZARI; MANTZARIS, 2013). Durante a aceleração de convergência, cujo objetivo é aumentar a velocidade que o algoritmo atinge um estado ótimo, ou próximo deste, em termos de sua função de custo ou objetivo, está sujeito ao surgimento de problemas durante o treinamento, como a persistência em mínimos locais, tempo de treinamento indefinido ou *overfitting* (Moriggi; Loh; Marques, 2020). Entende-se por *overfitting* quando, após um ciclo, a rede começa a piorar seu desempenho durante o treinamento. Isso ocorre porque a generalização do ambiente já foi concluída e, ao continuar o treinamento, a rede passa a sobrepor os pesos sinápticos adequados com informações sobre ruídos e peculiaridades do conjunto de dados, ou seja, *overfitting* ocorre quando um modelo é excessivamente complexo em relação aos dados disponíveis, resultando em uma baixa capacidade de generalização para novos dados (Haykin, 2009).

Os processos de treinamento não supervisionado não envolvem a comparação entre a saída obtida e desejada. Estes podem ser divididos em aprendizado por reforço e aprendizagem não-supervisionado.

O aprendizado por reforço é um tipo de aprendizado de máquina em que um agente aprende a se comportar em um ambiente, realizando ações e vendo os resultados. Em vez de ser informado sobre quais ações tomar, o agente deve descobrir quais ações geram mais recompensas, tentando-as (Haykin, 2009). Para Oliveira (2005), este paradigma é adequado para situações dinâmicas onde é inviável fornecer um conjunto de pares entrada-saída para o treinamento.

Em suma, a aprendizagem não-supervisionada, é caracterizada pela utilização na busca e obtenção de padrões significativos nos dados de entrada sem supervisão (Oliveira, 2005; Haykin, 2009). Importa realçar que a rede deve encontrar atributos estatísticos relevantes, desenvolvendo uma representação própria dos estímulos fornecidos à sua entrada. Por isso, deve haver redundância nos dados de entrada para possibilitar a identificação de padrões (Oliveira, 2005).

4.2.4 Algoritmo de regularização Bayesiana

O algoritmo de regularização Bayesiana (BR, do inglês, Bayesian Regularization), é aquele que utiliza a distribuição por dedução ou a *priori* para ajustar os pesos da rede neural, atualizando esta distribuição com os dados observados com vista a obter uma distribuição *posterior*, ajudando a prevenir o *overfitting* (Haykin, 2009).

Durante o treinamento de uma RNA usando regularização bayesiana, o objetivo principal é obter um desempenho que minimize o erro de aprendizado. Além disso, é importante que o aprendizado resultante possa representar adequadamente novas entradas de dados. Quando isso é alcançado, podemos afirmar que a rede possui uma boa capacidade de generalização.

O algoritmo de regularização bayesiana é recomendado para treinamento de redes neurais em avaliação de desempenho (Mackay, 1992; Bishop, 1995a; Heng *et al.*, 2022), no entanto, o mesmo proporciona uma abordagem cujo método é eficaz para prevenir o *overfitting*, incorporar conhecimentos prévios e fornecer estimativas probabilísticas robustas, elementos essenciais para a construção de modelos confiáveis e generalizáveis (Haykin, 2009).

Para o treinamento com o algoritmo de regularização bayesiana, este apresenta uma característica no conjunto de dados é dividido em duas, treinamento e teste (Bishop, 1995b). O conjunto de treinamento é a fase em se faz o ajuste dos pesos sinápticos; o conjunto de teste, estima a precisão da rede neural treinada ao aplicar um conjunto de dados que não foi utilizado durante o processo de treinamento.

4.2.5 Avaliação de desempenho

A energia solar enquanto uma fonte de energia alternativa às fontes convencionais, para colmatar algumas deficiências no setor energético angolano e não só, torna-se um desafio por conta das diferentes formas de aproveitamento desta ao se ter em conta fatores meteorológicos. Assim sendo, evitar perdas econômicas avultadas e aumentar a confiabilidade do sistema energético torna-se fundamental a precisão da previsão da irradiância solar. Deste modo, o desempenho do modelo é normalmente avaliado usando um conjunto de teste separado que não foi usado durante o período de treinamento do modelo, a fim de verificar a sua capacidade de generalização (James; Hastie; Tibshirani, 2013).

Segundo BISHOP (199b), as métricas de avaliação são cruciais para determinar o sucesso de um modelo, e elas devem ser escolhidas com base nos objetivos específicos e nas características do problema em questão. No entanto, os modelos de previsão podem ser amplamente classificados em abordagens físicas e estatísticas (Pelland *et al.*, 2013).

De acordo com Willmott e Matsuura (2005), os modelos com base as estatísticas ou métricas de erro são utilizados para comparar modelos de estimativa de observações independentes e confiáveis. Como as métricas de erro possuem diferentes formulações matemáticas, é esperado que os resultados obtidos por meio delas variem. Portanto, em muitos

casos, é necessário utilizar múltiplas métricas para fornecer uma análise abrangente da distribuição dos erros (Chai; Draxler, 2014). Em conformidade com Antonanzas *et al.* (2016) afirmam que o desempenho e a acurácia de um modelo específico podem ser avaliados utilizando diversas métricas de erro. Portanto, Hyndman e Athanasopoulos (2018) discutem várias métricas de avaliação de previsão, incluindo o MAPE enfatizando o seu uso devido à sua simplicidade e interpretabilidade. Neste trabalho foram utilizadas as seguintes métricas:

a) Erro Percentual Médio Absoluto (*Mean Absolute Percentual Error* – MAPE, do inglês)

A métrica MAPE é uma ferramenta de grande importância na avaliação de desempenho e frequentemente tem sido utilizada para comparar resultados de previsão, pois mede o erro em porcentagem. No contexto de avaliação de desempenho de modelos de previsão, isso se refere a um método ou técnica que ajuda na execução de tarefas específicas (Chatfield, 2000). Porém, o MAPE pode ser ineficaz quando o valor de saída desejado é baixo, devido à sua sensibilidade a valores extremos (Armstrong; Collopy, 1992; Makridakis; Wheelwright; Hyndman, 1998).

Assim, faz-se saber a relevância desta métrica, visto que o valor real da demanda se encontra no denominador, o MAPE pode assumir valores muito altos em situações de baixa demanda, Conforme a Equação (8).

$$\text{MAPE} = \frac{100}{N} \sum_{i=1}^N \left| \frac{P_i - p}{P_i} \right| \quad (7)$$

Sendo: P_i é a instância observada no ambiente, p é a instância estimada pelo modelo e N é o número de observações.

b) Erro Quadrático Médio da Raiz – (Root Mean Square Error – RMSE do inglês)

O RMSE, calculado pela Equação 10, mede a diferença entre os valores previstos e os valores observados, fornecendo uma estimativa da magnitude média do erro. É calculado como a raiz quadrada da média dos quadrados das diferenças entre os valores previstos e os valores observados. Portanto, o RMSE calcula a média dos erros de previsão, mas dá mais peso aos grandes erros ao elevar as diferenças ao quadrado antes de calcular a média. Essa métrica tem sido amplamente utilizada como padrão para avaliar o desempenho de modelos em áreas como meteorologia, qualidade do ar e pesquisas climáticas (Chai; Draxler, 2014).

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (p - P_i)^2} \quad (8)$$

Sendo: P_i é a instância observada no ambiente, p é a instância estimada pelo modelo e N é o número de observações.

4.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo, aborda em abordagem elementos que visam levar a compreensão dos principais pontos sobre redes neurais, com destaque nos seguintes pontos: redes neurais artificiais onde a definição do mesmo leva a fácil compreensão; definiu-se também o neurônio artificial sendo comparado ao neurônio biológico destacando a sua aplicação; na arquitetura das RNAs, cingiu-se e com particular realce para a rede do tipo *feedforward* de múltiplas camadas, pois é comumente usada em estudos de series temporais; em aprendizagem das RNAs com enfoque nos tipos de aprendizagem, a destacar o aprendizado supervisionado, referenciando os ajustes dos pesos iterativamente com base no erro calculado; para determinar como a rede será treinada e, conseqüentemente, como ela se comportará ao processar e interpretar os dados, foi usado o algoritmo de regularização bayesiana; a avaliação de desempenho do modelo é realizada usando duas métricas (MAPE e RMSE), conforme recomendado na literatura, para obter a melhor acurácia possível.

5 METODOLOGIA PROPOSTA

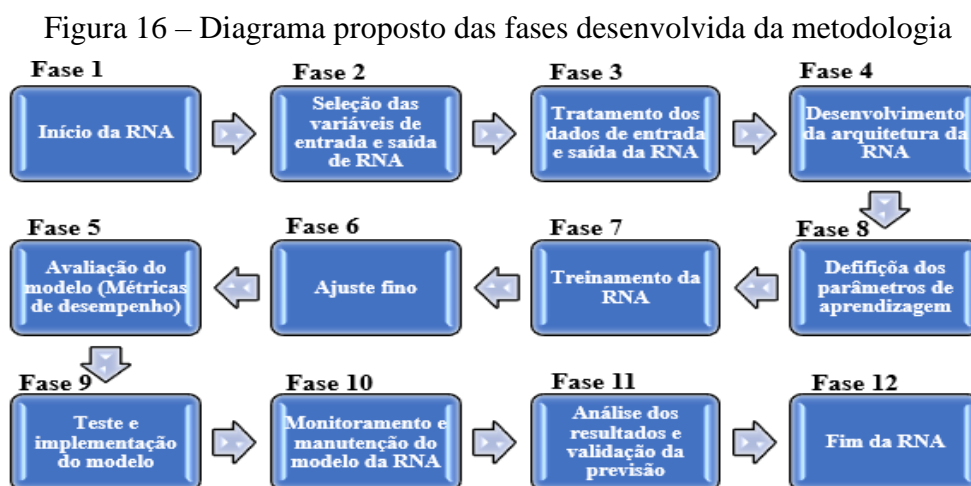
5.1 INTRODUÇÃO

Desenvolver uma arquitetura baseada em RNA com vista a melhorar a precisão da previsão da GHI, servindo-se da metodologia proposta Figura 16, como um guia, uma vez que é crucial para assegurar que a rede aprenda a mapear corretamente as entradas para as saídas desejadas, minimizando o erro e aprimorando a capacidade de generalização do modelo, é o grande objetivo traçado neste trabalho. Sendo que a energia proveniente de fontes fotovoltaicas tem se mostrado eficientes na melhoria das economias, oferecendo vantagens significativas como a redução de custos de eletricidade para consumidores finais.

Devido a sua flexibilidade e capacidade de processamento de grandes volumes de dados as RNAs vem sendo bastante utilizadas para estudos de previsão de GHI ao longo dos últimos anos (Yang; Wu; Kleissl, 2019).

Desta forma, propõe-se na metodologia deste trabalho, cuja objetivo é a previsão da GHI para fins de geração fotovoltaica, um modelo baseado em RNA, sendo uma rede do tipo *Perceptrons* Múltiplas Camadas (MLP).

Para melhor ilustração da metodologia proposta de previsão de GHI desenvolvida, na Figura 16 no diagrama estrutural, podendo ser observado cada uma das fases.



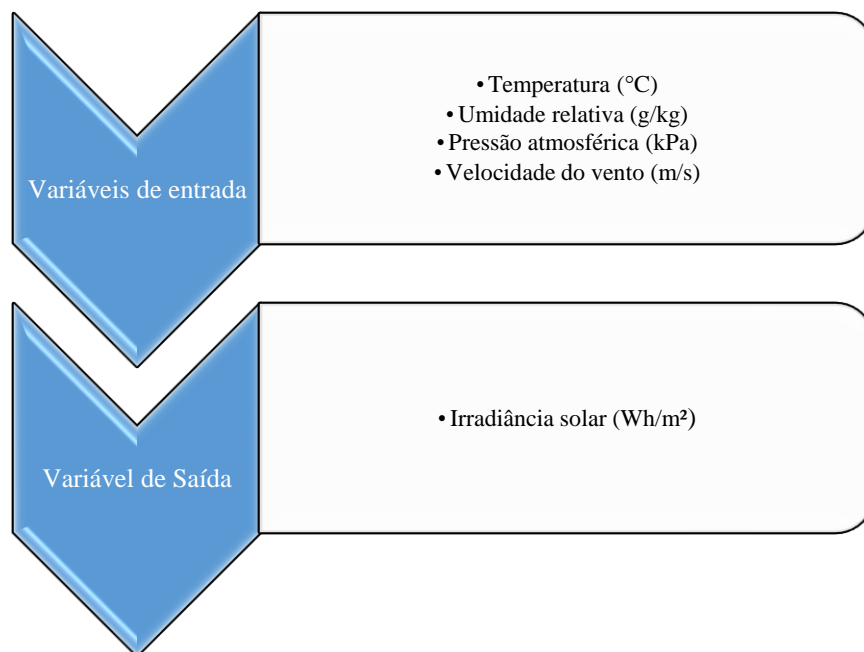
Fonte: próprio autor (2024).

A metodologia foi desenvolvida como consta da Figura 16, a fase 1 é na verdade a origem ou a idealização da mesma, na fase 2, efetuou-se a seleção das variáveis meteorológicas de entrada e saída. Assim, as variáveis de interesse selecionadas para este estudo servirão de

entrada para o modelo proposto, são: a temperatura atmosférica ($^{\circ}\text{C}$), a umidade relativa (g/kg), pressão atmosférica (kPa), e a velocidade do vento (m/s).

Quanto a variável de saída do modelo aquela a que se quer prever, é a irradiação solar (Wh/m^2). De acordo com a literatura, não existe uma ordem que determina a variável de entrada que a ser primeira na implementada no modelo, mas sim aquela que mais impacta para a previsão de GHI que no caso em específico trata-se da temperatura, os valores são medidos de hora em hora. As variáveis de entrada e saída do modelo são ilustradas no diagrama da Figura 17.

Figura 17 – Diagrama das variáveis de entrada e saída



Fonte: próprio autor (2024).

As definições das variáveis meteorológicas a serem usadas tem um papel fundamental para o bom funcionamento do modelo, outro elemento relevante ao lidar com as variáveis é o tratamento dos dados.

5.2 TRATAMENTO DOS DADOS DA RNA

O tratamento dos dados da RNA, faz parte da fase 3 da metodologia, como foi ilustrado na Figura 16. Para realização da previsão da irradiância global horizontal, os dados para as simulações foram obtidos do banco de dados da NASA e dados coletados nas estações meteorológicas gerenciadas pela Empresa de produção de eletricidade (PRODEL), localizadas

nas centrais fotovoltaicas do Biópio e da Baía-Farta na província de Benguela. Na Figura 18 ilustra-se o diagrama utilizado para o tratamento dos dados.

Figura 18 – Diagrama de tratamento de dados



Fonte: próprio autor (2024).

Atendendo a complexidade e quantidade de dados disponíveis, e para facilitar o processo de tratamento dos dados, estes foram tratados tendo em conta a sazonalidade existente no país, neste caso as estações chuvosa e seca. Desta forma, o treinamento da RNA destinada a previsão da estação chuvosa os dados utilizados compreende os meses de outubro até abril e a estação seca compreende os meses de maio até setembro dos anos de 2018 a 2022. Para os testes os dados utilizados são de 2023.

O “*Data cleaning*”, também conhecido como limpeza de dados, é um processo fundamental na análise de dados que envolve a identificação e correção de dados incorretos, incompletos, duplicados ou irrelevantes dentro de um conjunto de dados; para isso, foram realizados dois processamentos de pré-processamento:

Nas planilhas dos dados obtidos do banco de dados da NASA, correspondentes ao ano de 2018, nos meses de fevereiro e agosto encontrou-se dados com erro do tipo -999 e o mesmo ocorreu com os dados de março e novembro de 2020, tais dados foram descartados. Quanto aos dados coletados nas estações meteorológicas gerenciadas pela PRODEL, na estação da Baía-Farta, no período de março de 2023 a janeiro de 2024, nos meses de janeiro e novembro apresentaram erros de medição do tipo 0,0#; na estação do Biópio no período de janeiro de 2023 a janeiro de 2024, os meses mais críticos com erros diferentes foram: janeiro, junho, julho e novembro sendo erros do tipo 0,0# e 0,0%, sendo que os referidos erros acabaram por ser excluídos.

Definiu-se também critérios de exclusão de valores em caso de irregularidade ou não adequação sendo os seguintes:

- A temperatura deve ter os valores superiores a 0 °C;
- A umidade relativa do ar não pode apresentar valores negativos em (g/kg);
- A pressão atmosférica não pode ter valores negativos (kPa);

- A velocidade do vento deve estar entre 0 a 10 m/s;
- A irradiância solar não devem ser inferiores a 0 (Wh/m²).

A divisão do banco de dados de treinamento e teste para facilitar e melhor compreender o comportamento de cada período de acordo a sazonalidade em Angola, dividiu-se inicialmente os dados de acordo as duas estações existentes.

Quanto a definição de curto prazo *time step* (h+1) a janela de observação foi definida para prever a próxima hora (h+1).

5.3 DESENVOLVIMENTO DA ARQUITETURA DA RNA

A capacidade de aprendizado e generalização de uma rede neural artificial é determinada pela sua arquitetura. A escolha adequada da arquitetura é crucial para o sucesso da aplicação da rede a um problema específico (Haykin, 2009).

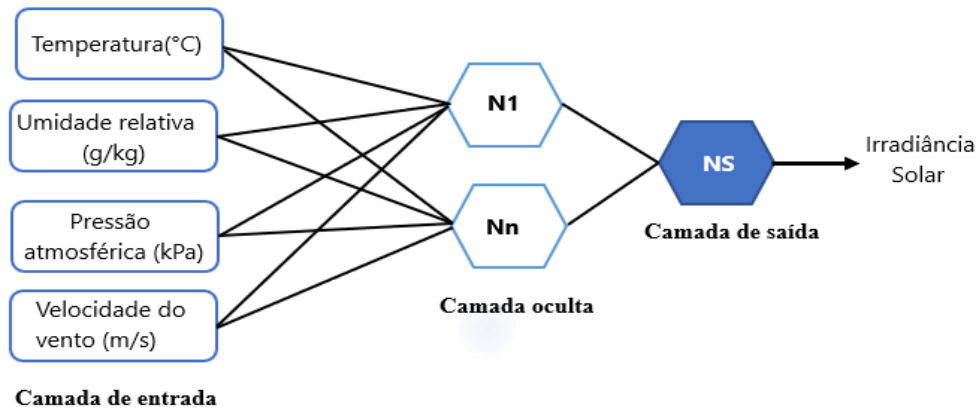
No processo de desenvolvimento do modelo são determinados os números de camadas, neurônios e a função de ativação. Conforme destacado por Haykin (2009), determinar o número de neurônios em cada camada da rede é de suma importância para o seu desempenho, especialmente no que diz respeito à sua habilidade de generalização.

Porém, não se destaca na literatura a quantidade de neurônios que deve existir para a resolução de um problema determinado, mas sabe-se que, quanto maior o número de neurônios, mais complexa se torna a rede e maior o seu alcance de solucionar o problema. No diagrama da Figura 16, é ilustrada a definição da arquitetura da RNA como sendo a quarta fase da metodologia proposta.

A arquitetura escolhida foi a, é *feedforward* Múltiplas Camadas *Perceptron* (MLP), sendo a mesma constituída por três partes: camada de entrada (*input layer*), camada intermediária ou camada oculta (*hidden layer*) e a terceira e última camada de saída (*output layer*), podendo ser observada na Figura 19.

E para rede reajustar seus pesos, para minimizar a função de perda, usou-se o algoritmo de treinamento regularização bayesiana com *backpropagation*. Este procedimento realizou-se por via da *Neural Network Toolbox* do MATLAB.

Figura 19 – Diagrama elucidativo da rede neural modelada e a especificação das entradas



Fonte: próprio autor (2024).

Como pode ser visto na Figura 19, uma MLP com três camadas foi implementada, sendo a primeira de entrada com as quatro variáveis de entrada, a camada oculta, a como função de ativação logística, e a camada de saída linear. Foram testadas diferentes quantidades de neurônios na camada oculta.


Depois de determinar a arquitetura da RNA que é um marco fundamental, pois remete-nos a seleção de quantidade de camadas e neurônios que serão responsáveis na determinação das interações e aprendizagem do modelo, urge a necessidade da definição de uma metodologia dos parâmetros de aprendizagem da RNA.

5.4 METODOLOGIA DE TREINAMENTO DA RNA

Na figura 16 onde ilustra-se o diagrama da metodologia proposta, as fases 5 e 6 observam-se dois pontos importantes para a compreensão da metodologia de treinamento da RNA, pois o treinamento da RNA destaca-se com vista a resolução de problemas, que no caso específico trata-se da previsão de GHI que incorpora dados passados ou series temporais. Assim, a utilização das *toolbox* do MATLAB R2015b, com recurso a rede MLP, sendo o algoritmo de treinamento regularização bayesiana. Em que, o propósito principal do algoritmo regularização bayesiana, é o de prevenir o sobreajuste (*overfitting*). Destaca-se também nesta proposta, o treinamento supervisionado, pois a rede é treinada a partir da combinação dos padrões de entrada e saída. Para o treinamento da rede, utilizou-se 70% do conjunto de dados de acordo a cada estação do ano, enquanto que para o teste, usou-se 30% dos dados.

Com o objetivo de identificar a melhor rede uma vez que se tem dados de duas instituições diferentes sendo da NASA e a PRODEL, fez-se o uso da rede neural em duas fases, as mesmas podem ser vistas na Figura 20.

Figura 20 – Fases de utilização da RNA



Fonte: adaptado de Capo (2018).

Complementarmente, para a realização da previsão, análise de resultados e cálculo das métricas culminando com a avaliação da capacidade do modelo foi utilizado o conjunto de dados da PRODEL.

A sétima fase da metodologia proposta, traz em abordagem o ajuste fino (*fine-tuning* do inglês) que, de acordo com Hinton *et al.* (2015) definem ajuste fino como o processo de treinar adicionalmente um modelo previamente treinado para uma nova tarefa ou para melhorar a eficiência, ajustando seus parâmetros, tais com; número de camadas, número de neurônios, taxa de aprendizado e funções de ativação. Para o caso específico na Figura 20, trata-se da segunda fase, onde o conjunto de dados de previsão que são um conjunto de dados que o modelo não viu durante o treinamento. Eles são usados para avaliar o desempenho do modelo de maneira imparcial. Dessa forma, o ajuste fino é sempre seguido pela avaliação de desempenho para garantir que as modificações tenham realmente melhorado o modelo para a nova tarefa.

Após o cumprimento das fases 5, 6 e 7 como consta do diagrama da Figura 16, se faz necessário a compreensão do estudo da metodologia para avaliação de desempenho.

5.5 METODOLOGIA PARA AVALIAÇÃO DE DESEMPENHO

De acordo com Géron (2022), uma boa metodologia de avaliação de desempenho é fundamental para compreender e melhorar o desempenho dos modelos de aprendizado de máquina. Sem uma avaliação adequada, corre-se o risco de implementar modelos que podem ter um desempenho insatisfatório em dados invisíveis. Para esta fase tornou-se relevante a verificação das métricas mais comumente usadas. Desta forma, o coeficiente de correlação de Pearson (R) é utilizado na primeira fase de avaliação, durante o treinamento do modelo. A segunda fase onde são realizados os testes de previsão as métricas previamente selecionadas foram: Erro Percentual Médio Absoluto (MAPE) e Raiz do Erro Médio Quadrático (RMSE),

as mesmas podem ser observadas nas equações (7) e (8). As métricas referenciadas têm o seu uso frequente na engenharia e com particular realce na indústria de energia renovável, com objetivo de avaliar o desempenho das previsões, tendo em conta a singularidade de cada, para o caso do MAPE tem a sua utilização para a interpretação relativa do erro. Quanto ao RMSE, é útil em aplicações onde a precisão é crítica, ou seja, é utilizado para medir o desvio padrão dos valores.

Portanto, a obtenção do melhor resultado é alcançada por meio de uma análise abrangente utilizando o coeficiente de correlação de Pearson, MAPE e o RMSE. Estas métricas fornecem diferentes perspectivas sobre a magnitude e a natureza dos erros. Posteriormente, é considerado o valor médio dos resultados previstos pela RNA.

5.6 TESTE E IMPLEMENTAÇÃO DO MODELO DA RNA

A descrição do teste e a implementação de um modelo de RNA, implica dar seguimento a estrutura da metodologia proposta no diagrama da Figura 16, uma vez que, o teste deve garantir que o modelo forneça previsões precisas em relação aos dados históricos e de validação, avaliando a capacidade do modelo de generalizar para novos dados não vistos anteriormente bem como detectar e corrigir possíveis problemas, como *overfitting*.

Deve por outro lado, desempenhar função como verificar se o modelo opera dentro dos limites de tempo e recursos computacionais aceitáveis para o ambiente pelo qual é construído, tendo em conta a robustez do mesmo frente a dados ruidosos ou anormais, permitindo assim, ajustes finais do modelo, incluindo a otimização de hiperparâmetros e melhoria da arquitetura da rede antes da sua implementação final, assegurando que o modelo atenda aos requisitos e especificações do projeto, onde se destaca a avaliação de desempenho, e a precisão.

De acordo com Lecun, Bengio e Hinton (2015) torna-se essencial testar as redes neurais para verificar se os modelos podem generalizar para novos dados que não foram vistos ou correlacionados durante o treinamento para prevenir o *overfitting*. Já a implementação de redes neurais em um ambiente de produção requer adaptar o modelo para operar de maneira eficiente e continuar monitorando para assegurar que ele mantenha um desempenho consistente (Haykin, 2009). Assim, a implementação implica documentar todo processo desenvolvido para a elaboração do modelo para facilitar o treinamento dos operadores e usuário.

Portanto, a fase 9 da metodologia proposta se torna fundamental, uma vez que visa enfatizar a importância de garantir a robustez em ambiente real e a generalização, pois são

elementos essenciais que garantem a confiabilidade e precisão das previsões do modelo desenvolvido.

5.7 MONITORAMENTO E MANUTENÇÃO DO MODELO DA RNA

A fase 10 da metodologia proposta na Figura 16, torna-se relevante em países subdesenvolvidos sob o ponto de vista da importância do monitoramento e manutenção de sistemas, softwares ou no caso específico o modelo da RNA, por conta de enfrentarem diversos desafios que se pode incluir, a infraestrutura, recursos humanos e financeiros.

No entanto, torna-se crucial após a implementação de um modelo de previsão de GHI, monitorar e manter o mesmo com vista a garantir que este continue fornecendo previsões precisas ao longo do tempo. Por conseguinte, o monitoramento contínuo possibilita a não perder de vista o desempenho das métricas usadas; verificar se a distribuição das variáveis de entrada mudou com o tempo (*drift* de dados) e o monitoramento da acurácia dos valores previstos em relação aos valores reais. Outrossim, possibilita o retreinamento do modelo de forma periódica utilizando novos dados e adapta-los para novas condições.

De acordo com Fernandes, Oliveira e Souza (2021), a manutenção de RNAs envolve a atualização periódica dos pesos e parâmetros do modelo com novos dados de treinamento, garantindo que o sistema permaneça ajustado a possíveis mudanças nas condições atmosféricas. Desse modo, a manutenção preventiva, ajuda na avaliação e ajuste dos hiperparâmetros e da arquitetura com regularidade, ajuda também na identificação e correção de possíveis hiperparâmetros que possam surgir.

Portanto, o monitoramento e a manutenção do modelo da RNA, de forma contínua e proativa, servem para assegurar a precisão bem como a confiabilidade das previsões de GHI.

5.8 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo detalhou-se a metodologia proposta, detalhando cada uma das fases propostas no diagrama da Figura 16. Tendo como ponto de partida a compreensão da seleção das variáveis de entrada e saída do modelo proposto, tratamento dos dados de entrada e saída da modelo, desenvolvimento da arquitetura da RNA.

A seguir, a definição ou modelagem dos parâmetros de aprendizagem da RNA, onde destacam-se: número de camadas, número de neurônios, função de ativação, algoritmo de treinamento; a metodologia de treinamento da RNA, com realce para a divisão percentual dos

dados de treinamento e teste, tendo em conta a sazonalidade do país. Para aferir a eficiência e o grau de confiabilidade dos resultados previstos, foi introduzido o ajuste fino, seguido da metodologia de avaliação de desempenho com recurso a métricas com objetivo de definir o melhor resultado previsto. Por fim o teste e implementação da RNA.


6 RESULTADOS E DISCUSSÃO

A determinação da base de dados serve de elemento fundamental para abordagem do capítulo em questão, uma vez que os dados obtidos da base de dados da NASA perfaz um total de 8.760 dados a destacar a estação chuvosa com 5.088 dados contabilizados dentre os quais foram divididos 70% para o treinamento que corresponde a 3.561 e 30% para teste que corresponde a 1.527 dados; para estação seca sendo 3.672, dos quais 70% para treinamento 2.570 e 30% para teste 1.102 dados que foram utilizados para o treinamento e teste da rede.

Os dados recebidos da PRODEL, após tratamento do mesmo e comparação com os dados da NASA, foram utilizados para o treinamento, teste e avaliação de desempenho da rede desenvolvida, sendo um total de 8.615 dados, sendo de igual modo repartidos de acordo as estações, para a estação chuvosa de 5.188 dados, divididos igualmente para treinamento e teste, 70% correspondente a treinamento igual a 3.632 dados e 30% teste igual a 1.556 dados, já para a estação seca total de dados é de 3.427, e 70% de treinamento igual a 2.399 dados e 1.028 dados para teste. De salientar que estes dados foram utilizados após o processo de tratamento dos mesmos, ou seja, sem qualquer erro nas medições.

O desenvolvimento do modelo da RNA, que se frisou na seção 5.3, como ilustrado na Figura 21, foi desenvolvida com recurso do *software* MATLAB, possibilitando a utilização desta para realizar treinamentos que levaram a obtenção de resultados importantes.

Figura 21 – Arquitetura da RNA desenvolvida

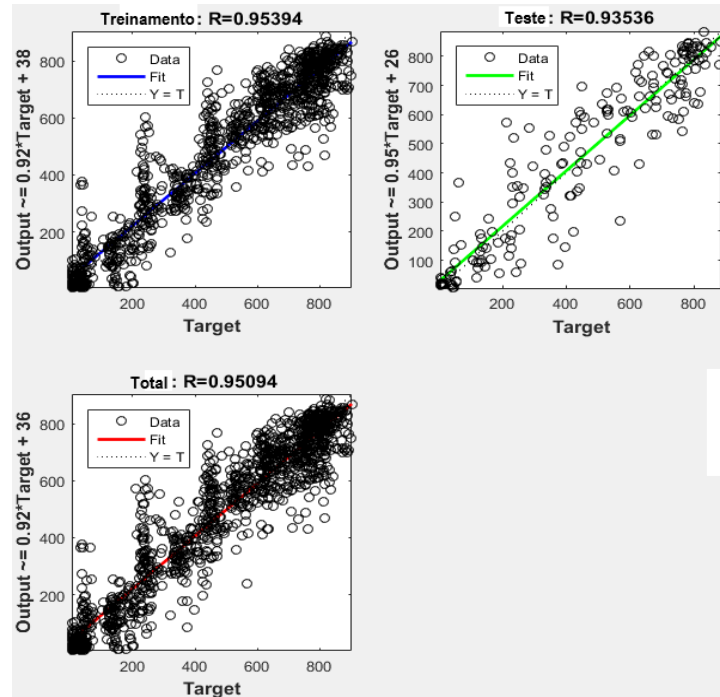


Fonte: próprio autor (2024).

Na Figura 22 e 23, ilustram-se o coeficiente de correlação dos conjuntos de dados obtidos no período de treinamento e teste. É notório que a resposta alcançada nas três situações, o resultado obtido cerca-se muito ao valor desejado demonstrando um ótimo desempenho. De acordo com SENGUPTA *et al.* (2021), em estudos de previsão de GHI, um coeficiente de correlação superior a 0,8 é geralmente considerado um indicador de bom desempenho do

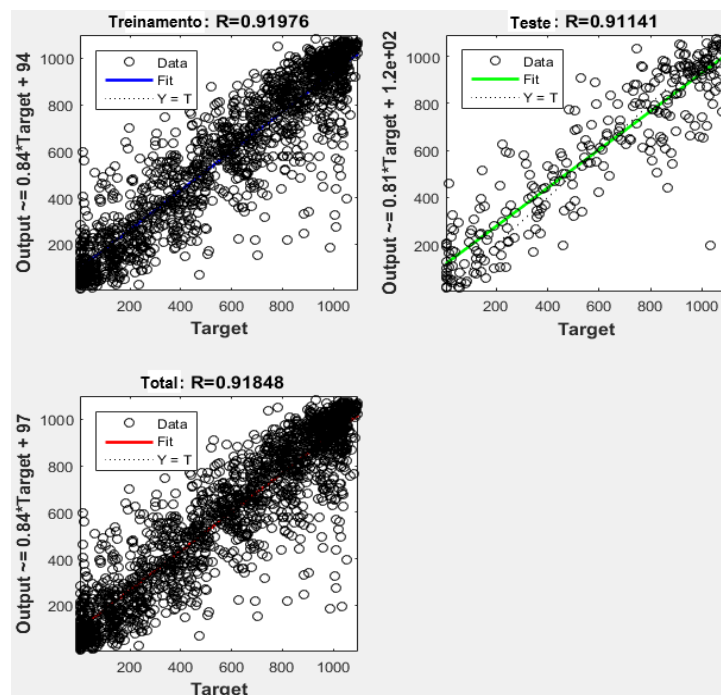
modelo. No entanto, a aceitação de um valor específico pode variar conforme a aplicação e as condições climáticas do local em estudo.

Figura 22 – Resposta da rede durante a fase de treinamento para a estação chuvosa no mês de abril dias 5 e 7



Fonte: próprio autor (2024).

Figura 23 – Resposta da rede durante a fase de treinamento para a estação Seca




Fonte: próprio autor (2024).

Assim, relativamente aos valores de correlação, conclui-se que estes apresentam uma ligação direta com as condições climáticas locais, bem como as variáveis de entrada que são determinadas para o estudo. Conforme James, Hastie e Tibshirani (2013), os autores concluem que a seleção adequada das variáveis de entrada é importante para o desempenho do modelo preditivo.

No entanto, as variáveis escolhidas influenciam diretamente o coeficiente de correlação nas fases de treinamento e teste, com variáveis bem selecionadas resultando em previsões mais precisas e um coeficiente de correlação mais elevado. Desta forma, na seção 3.5 teve-se em conta a análise dos fatores que influenciam na previsão de GHI onde por meio da Figura 24, se apresenta os resultados da comparação entre as respostas dada pela rede e o valor real, onde buscou-se prever a GHI usando cada uma das quatro variáveis de forma independente, podendo concluir-se que a temperatura atmosférica é responsável de quase 90% da resposta dada pela rede. Destaca-se que, esta comparação foi feita para a estação chuvosa.

Figura 24 – Comparação entre as respostas dada pela rede, valor real e das variáveis



Fonte: próprio autor (2024).

Portanto, o coeficiente de correlação com valores elevado é um elemento que serve de base para a seleção do melhor modelo de previsão de acordo com vários trabalhos consultados.


O resultado mais eficaz foi obtido com 26 neurônios na estação seca, e 46 neurônios na estação chuvosa.

No presente trabalho é proposto a previsão de GHI usando as RNAs para curto prazo, podendo dar respostas de despachos diários para a satisfação da demanda, para que se alcance o referido propósito, calculou-se as métricas como descritas na seção 4.2.5 para aferir a avaliação de desempenho, determinando assim o melhor resultado da previsão para cada período sazonal, são apresentados na Quadro 2, sendo MAPE e RMSE obtidos pela RNA.

No Quadro 2, nota-se que os valores de MAPE e RMSE da estação chuvosa, são menores em relação ao da estação seca, levando-nos a compreender que a rede previu melhor neste período sazonal, onde obteve-se também maior incidência solar e menos umidade relativa.


Contudo, nas Figura 24 e 25 pode-se observar os resultados obtidos pela rede neural *feedforward* com *backpropagation*, com algoritmo de regularização bayesiana para previsão de radiação solar para ambas estações, tendo sido aplicado o avanço de curto prazo (*time step* horário, $h+1$) e que a referida aplicação foi feita na planilha de dados. Segundo Voyant *et al.* (2017) modelos baseados em dados terrestres em geral preservam sua acurácia para horizontes temporais de até algumas horas à frente.

Figura 25 – Resultado previsto pela rede (estação chuvosa, mês de abril dias 5 e 7).



Fonte: próprio autor (2024).

Figura 26 – Resultado previsto pela rede (estação seca, mês de julho dias 12 e 13).



Fonte: próprio autor (2024).

Por via de regra, para a avaliação da precisão e confiabilidade dos modelos de previsão, são empregues o cálculo de erros percentuais nos estudos de previsão, e para o caso específico que é o de desenvolver um modelo de previsão de GHI, o objetivo visa: avaliar o modelo, permitindo a identificação de assimetrias entre os valores reais e os previstos, visando a eficácia do modelo; aperfeiçoar o algoritmo, isto passa por ajustar os parâmetros dos modelos, tornando-os em algoritmos mais precisos e robustos; planejar e tomar decisões, uma vez que em geração fotovoltaica para o planejamento é fundamental previsões precisas de GHI, por outro lado a tomada de decisão ajuda no dimensionamento, bem como na gestão de recursos energéticos; por fim auxiliar na comparação de modelos.

Calculou-se os erros percentuais por meio da equação 9, os resultados dos cálculos também podem ser observados no Quadro 2.

$$Erro \% = \left| \frac{\text{média real} - \text{média prevista}}{\text{média real}} \right| \times 100\% \quad (9)$$

Quadro 2 – Demonstração dos resultados de acordo as estações

Estação	RMSE (Wh/m ²)	MAPE (%)	Tempo de Processamento (s)	Média Real (Wh/m ²)	Média Prevista (Wh/m ²)	Erro (%)
Seca (Mês de julho, dias 12 e 13)	79,29	10,16	0,12	377,02	354,80	5,89
Chuvosa (Mês de abril, dias 5 e 7)	61,15	7,12	0,29	365,53	343,20	6,10

Fonte: próprio autor (2024).

Portanto, a divisão dos dados de acordo a sazonalidade do país, ajudou no processo e desenvolvimento do modelo, pois, dispõe de características com ligeiras diferenças nas condições meteorológicas ao longo do ano. Assim, média de erro de cada estação chuvosa demonstra uma boa capacidade de previsão do modelo desenvolvido.

7 CONSIDERAÇÕES FINAIS

Este capítulo tem como objetivo apresentar as conclusões alcançadas no estudo, propor futuros trabalhos e listar os artigos publicados durante a pesquisa.

7.1 CONCLUSÕES

O presente trabalho teve como objetivo geral, desenvolver um modelo de aprendizado de máquina para melhorar a previsão da irradiância solar em curto prazo ($h+1$) e otimizar a geração de energia fotovoltaica, nos municípios da Baía-Farta e do Lobito na comuna do Biópio, na província de Benguela - Angola.

A radiação solar que atinge a superfície da terra sofre influência de forma direta dos fatores meteorológicos, influenciando assim a eficiência da geração de energia fotovoltaica. Para melhor responder a previsão que se propôs o trabalho, foram utilizadas como variáveis meteorológicas de entrada as seguintes: a temperatura atmosférica ($^{\circ}\text{C}$), a umidade relativa (g/kg), pressão atmosférica (kPa), e a velocidade do vento (m/s). Quanto a variável de saída do modelo aquela a que se quer prever, é a irradiação solar (Wh/m^2). Com um total de 8.760 dados obtidos no website da NASA e 8.615 dados medidos nas estações meteorológicas sobe a égide da PRODEL. A arquitetura utilizada foi a *Multilayer Perceptron*, comumente usados em estudos de predição de variáveis meteorológicas.

De acordo com a metodologia proposta, o modelo mostrou-se eficaz durante o período de treinamento e previsão da irradiância solar, pois um dos pontos fulcrais que é o tratamento dos dados de entrada e saída da RNA cumpriu-se com os pré-processamentos e seus critérios que culminaram com a exclusão de dados que não obedecessem aos referidos critérios.

As métricas utilizadas para avaliação de desempenho demonstraram bons resultados quando com parados a trabalhos consultados, tendo um MAPE = 10, 16% e RMSE = 79,29 Wh/m^2 para a estação seca e para a estação chuvosa o MAPE = 7, 12% e RMSE = 61,15 Wh/m^2 . O cálculo do erro percentual serviu também como um elemento importante para se tirar as melhores ilações.

Por fim, constatou-se que a aplicação de RNA para prever a GHI para curto prazo ($h+1$) e dessa forma, melhorar a precisão da previsão, o modelo desenvolvido mostra-se adequado dado o potencial demonstrado, tendo como principal enfoque o despacho de energia; augura-se também, otimizar a produção de energia e a integração fotovoltaica para rede elétrica nacional, assim como, na tomada de decisões relacionadas ao dimensionamento de sistemas solares; no

gerenciamento de energia e manutenção de infraestrutura, podendo levar a redução de custos operacionais, agudizando a eficiência das plantas solares.

7.2 TRABALHOS FUTUROS

Seguindo a linha de pesquisa que acredito ser de grande importância por conta da crescente demanda por energia, sendo as fontes renováveis as mais solicitadas e sobretudo as de geração fotovoltaica pelo fácil manuseio, perspectiva para os trabalhos futuro as seguintes recomendações:

Construir um modelo com uma metodologia semelhante ou diferente e utilizar outros algoritmos de *machine learning* ou *deep learning*.

Desenvolver um modelo para previsão de GHI usando dados meteorológicos, com objetivo de melhorar o armazenamento de energia.

REFERÊNCIAS

- AFRICAN UNION COMMISSION. **Africa's Development Dynamics 2023**: investing in sustainable development. Paris: Addis Ababa/Oecd Publishing, 2023. 249 p.
- ÁGUIA, D. V. A. **Previsão de produção solar fotovoltaica através do modelo elétrico**. 2016. 66 f. Dissertação (Mestrado) - Curso de Engenharia Eletrotécnica e de Computadores, Faculdade de Engenharia, Universidade do Porto, Porto, 2016.
- AHRENS, C. D.; HENSON, R. **Meteorology Today**: an introduction to weather, climate, and the environment. 11. ed. [S. l.]: Cengage Learning, 2015. 640 p.
- AL-HAJJ, R. *et al.* A hybrid LSTM-based genetic programming approach for short-term prediction of global solar radiation using weather data. **Processes**, Basel, v. 9, n. 7, p. 1187, 2021.
- ALLARD, J.; FENG, W. **Introduction to Weather and Climate (VSU)**. [S. l.]: Geological Sciences and Geography, 2018.
- ANGOLA. **Decreto Presidencial nº 43/21, de 17 de fevereiro de 2021**. Regulamento de produção independente de energia eléctrica. Luanda: Diário da República, 2021.
- ANGOLA. Ministério da Energia e Águas. **Renováveis: solar**. 2017. Disponível em: <https://angolaenergia2025.gestoenergy.com/pt-pt/conteudo/renovaveis-solar>. Acesso em: 24 Jun. 2023.
- ANGOLA. Ministério de Energia e Águas. **Atlas and national strategy for the new renewable energies**. [S. l.]: MINEA, 2014.
- ANTONANZAS, J. *et al.* Review of photovoltaic power forecasting. **Solar energy**, Oxford, v. 136, p. 78-111, 2016.
- ARAÚJO, L. A. **Projeto de um seguidor para coberturas, destinado a painéis solares**. 2012. Dissertação (Mestrado em Engenharia Mecânica) - Departamento de Engenharia Mecânica, Universidade do Minho, Guimarães, 2012.
- ARMSTRONG, J. S.; COLLOPY, F. Error measures for generalizing about forecasting methods: empirical comparisons. **International Journal of Forecasting**, Amsterdam, v. 8, n. 1, p. 69-80, 1992.
- BAASHAR, Y. *et al.* Toward predicting student's academic performance using artificial neural networks (ANNs). **Applied Sciences**, Basel, v. 12, n. 3, p. 1289, 2022.
- BACERRA-RANDON, A.; DUCATI, J.; HAAG, R. Análise anual das componentes direta, difusa e global da radiação solar em Porto Alegre, RS. *In*: Congresso Brasileiro de Energia Solar, 8., 2020, Fortaleza. **Anais [...]**. São Paulo: ABENS, 2020. p. 1-8.
- BADESCU, V. **Modeling solar radiation at the Earth's surface**. Heidelberg: Springer-Verlag, 2008.

- BAMISILE, O. *et al.* An approach for sustainable energy planning towards 100% electrification of Nigeria by 2030. **Energy**, London, v. 197, p. 117172, 2020.
- BEER, C. *et al.* Terrestrial gross carbon dioxide uptake: global distribution and covariation with climate. **Science**, Washington, v. 329, n. 5993, p. 834-838, 2010.
- BENGHANEM, M. J. A. E. Optimization of tilt angle for solar panel: Case study for Madinah, Saudi Arabia. **Applied Energy**, Oxford, v. 88, n. 4, p. 1427-1433, 2011.
- BENMOUIZA, K.; CHEKNANE, A. Clustered ANFIS network using fuzzy c-means, subtractive clustering, and grid partitioning for hourly solar radiation forecasting. **Theoretical and Applied Climatology**, Wien, v. 137, p. 31-43, 2019.
- BISHOP, C. M. Training with noise is equivalent to Tikhonov regularization. **Neural computation**, Cambridge, v. 7, n. 1, p. 108-116, 1995a.
- BISHOP, C. M. **Neural networks for pattern recognition**. Oxford: Oxford university press, 1995b.
- BOUBAKER, S.; KAMEL, S.; KCHAOU, M. Prediction of daily global solar radiation using resilient-propagation artificial neural network and historical data: a case study of hail, Saudi Arabia. **Engineering, Technology & Applied Science Research**, [S. l], v. 10, n. 1, p. 5228-5232, 2020. Disponível em: pdfs.semanticscholar.org. Acesso em: 24 Jun. 2023
- BRAGA, A. P.; LUDERMIR, T. B.; CARVALHO, A. C. P. L. F. **Redes neurais artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro: LTC, 2007.
- BUCKMAN, J. *et al.* Sample-efficient reinforcement learning with stochastic ensemble value expansion. **Advances in neural information processing systems**, Maryland Heights, v. 31, p. 1-11, 2018.
- CALDAS, M.; ALONSO-SUÁREZ, R. Very short-term solar irradiance forecast using all-sky imaging and real-time irradiance measurements. **Renewable energy**, Oxford, v. 143, p. 1643-1658, 2019.
- CAMPO-ÁVILA, J. *et al.* A data mining system for predicting solar global spectral irradiance. Performance assessment in the spectral response ranges of thin-film photovoltaic modules. **Renewable Energy**, Oxford, v. 133, p. 828-839, 2019.
- CAMPO-ÁVILA, J. *et al.* Binding data mining and expert knowledge for one-day-ahead prediction of hourly global solar radiation. **Expert Systems with Applications**, Oxford, v. 167, p. 114147, 2021.
- CAPO, P. Í. M. **Desenvolvimento de uma ferramenta para previsão de curto prazo da radiação solar utilizando redes neurais artificiais**. 2018. 82 f. Dissertação (Mestrado) - Curso de Energia e Sustentabilidade, Universidade Federal de Santa Catarina, Araranguá, 2018.

CHAI, T.; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, Goettingen, v. 7, n. 3, p. 1247-1250, 2014.

CHAIBI, Y. *et al.* Solar irradiance and temperature influence on the photovoltaic cell equivalent-circuit models. **Solar Energy**, Oxford, v. 188, p. 1102-1110, 2019.

CHAKRABORTY, S. *et al.* Distribution-aware sampling and weighted model counting for SAT. *In: Proceedings of the AAAI Conference on Artificial Intelligence*, 28., 2014, Québec. **Anais [...]**. Palo Alto: AAAI Press, 2014. p. 1722-1730.

CHATFIELD, C. **Time-series forecasting**. CRC Press: Flórida, 2000.

CHITEKA, K.; ENWEREMADU, C. C. Prediction of global horizontal solar irradiance in Zimbabwe using artificial neural networks. **Journal of Cleaner Production**, Amsterdam, v. 135, p. 701-711, 2016.

CITAKOGLU, H.; BABAYIGIT, B.; HAKTANIR, N. A. Solar radiation prediction using multi-gene genetic programming approach. **Theoretical and Applied Climatology**, Wien, v. 142, p. 885-897. 2020.

CUI, C. *et al.* Evaluating combination models of solar irradiance on inclined surfaces and forecasting photovoltaic power generation. **IET Smart Grid**, Stevenage, v. 2, n. 1, p. 123-130, 2019.

DIAGNE, M. *et al.* Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. **Renewable and Sustainable Energy Reviews**, Oxford, v. 27, p. 65-76. 2013.

ECHER, M. P.; MARTINS, F. R.; PEREIRA, E. B. A importância dos dados de cobertura de nuvens e de sua variabilidade: metodologias para aquisição de dados. **Revista Brasileira de Ensino de Física**, São Paulo, v. 28, p. 341-352, 2006.

FERNANDES, R. A. S. **Identificação de fontes de correntes harmônicas por redes neurais artificiais**. 2009. 127 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Escola de Engenharia, Universidade de São Paulo, São Carlos, 2009.

FERNANDES, T.; OLIVEIRA, M.; SOUZA, P. Adaptive maintenance strategies for neural networks in solar radiation prediction. **International Journal of Energy Research**, Oxford, v. 45, n. 5, p. 876-889, 2021.

FIORIN, D. V. *et al.* Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. **Revista Brasileira de Ensino de Física**, São Paulo, v. 33, p. 01-20, 2011.
FRITTS, C. E. On a new form of selenium cell, and some electrical discoveries made by its use. **American Journal of Science**, New Haven, v. 3, n. 156, p. 465-472, 1883.

GANA, N. N.; AKPOOTU, D. O. Estimation of global solar radiation using four sunlight-based models in Kebbi, North West, Nigeria. **Advances in Applied Science Research**, v. 4, p. 409-421, 2013.

- GÉRON, A. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow. Sebastopol: O'Reilly Media, 2022.
- GHOFRANI, M. *et al.* A hybrid short-term load forecasting with a new input selection framework. **Energy**, London, v. 81, p. 777-786, 2015.
- GÓMEZ-EXPÓSITO, A.; CONEJO, A. J.; CAÑIZARES, C. (ed.). **Electric energy systems: analysis and operation**. CRC press: Flórida, 2018.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Cambridge: MIT Press, 2016.
- GRIFFITHS, I. **O Atlas dos Assuntos Africanos**. London: Taylor e Francis, 2013.
- HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the Marquardt algorithm. **IEEE transactions on Neural Networks**, Piscataway, v. 5, n. 6, p. 989-993, 1994.
- HAYKIN, S. **Neural networks and learning machines**. 3rd. ed. Saddle River: Prentice Hall, 2009.
- HAYKIN, S. **Neural networks: a comprehensive foundation**. Saddle River: Prentice Hall, 1999.
- HENG, S.Y. *et al.* Artificial neural network model with different backpropagation algorithms and meteorological data for solar radiation prediction, **Scientific Reports**, London, v. 12, n. 1, p. 1-18, 2022. DOI: 10.1038/s41598-022-13532-3.
- HINTON, G.; VINYALS, O.; DEAN, J. Distilling the knowledge in a neural network. **ArXiv preprint arXiv:1503.02531**, [S. l.], v. 2, n. 5, p. 1-9, 2015.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. Melbourne: OTexts, 2018.
- INMAN, R. H.; PEDRO, H. T. C.; COIMBRA, C. F. M. Solar forecasting methods for renewable energy integration. **Progress In Energy and Combustion Science**, Oxford, v. 39, n. 6, p.535-576, 2013.
- INSTITUTO NACIONAL DE ESTATÍSTICA – INE. Resultados definitivos do recenseamento geral da população e da habitação de Angola 2014. Luanda: INE, 2016.
- INSTITUTO NACIONAL DE METEOROLOGIA E GEOFÍSICA – INAMET. **Previsão Sazonal**. Cabo Verde: INAMET, 2021. Disponível em: www.inamet.gov.ao. Acesso em: 01 dez. 2023.
- INTERNATIONAL ENERGY AGENCY – IEA. **World Energy Outlook 2021**. [S. l.]: IEA, 2021.
- INTERNATIONAL RENEWABLE ENERGY AGENCY – IRENA; AFRICAN DEVELOPMENT BANK GROUP – AfDB. **Renewable Energy market analysis: Africa and its regions**. Abu Dhabi, Abidjan: IRENA and AfDB, 2022.

INTERNATIONAL RENEWABLE ENERGY AGENCY – IRENA; FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS – FAO. **Renewable energy for agri-food systems: Towards the Sustainable Development Goals and the Paris Agreement.** Abu Dhabi, Roma: IRENA and FAO, 2021.

IQBAL, M. **An introduction to solar radiation.** New York: Academic Press, 1983.

JAMES, G.; HASTIE, T.; TIBSHIRANI, R. **An introduction to statistical learning.** New York: Springer, 2013.

JANG, J. S. R.; SUN, C. T.; MIZUTANI, E. **Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence.** Saddle River: Prentice Hall, 1997.

JIA, D. *et al.* Estimations of global horizontal irradiance and direct normal irradiance by using Fengyun-4A satellite data in northern China. **Remote Sensing**, Basel, v. 13, n. 4, p. 790, 2021. DOI: <https://doi.org/10.3390/rs13040790>.

KALOGIROU, S. A. Artificial intelligence for the modeling and control of combustion processes: A review. **Progress in Energy and Combustion Science**, Oxford, v. 27, n. 6, p. 523-570, 2001.

KAMINSKI JÚNIOR, A. M. Emprego de redes neurais artificiais para predição de temperatura de topo de óleo e perda de vida útil em transformadores de potência. 2020. 103 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Centro de Tecnologia, Universidade Federal de Santa Maria, Santa Maria, 2020.

KHAN, M. A.; GADIWALA, M. S. A study of drought over Sindh (Pakistan) using standardized precipitation index (SPI) 1951 to 2010. **Pakistan Journal of Meteorology**, [S. l.], v. 9, n. 18, p. 15-22, 2013.

KHOSRAVI, A. *et al.* Prediction of wind speed and wind direction using artificial neural network, support vector regression and adaptive neuro-fuzzy inference system. **Sustainable Energy Technologies and Assessments**, Amsterdam, v. 25, p. 146-160, 2018.

KUHE, A.; ACHIRGBENDA, V. T.; AGADA, M. Global solar radiation prediction for Makurdi, Nigeria using feed forward backward propagation neural network. **Journal of Renewable Energy and Environment**, MeshkinDasht, v. 5, n. 1, p. 51-55, 2018.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, London, v. 521, n. 7553, p. 436-444, 2015.

LIMA, M. História da África: temas e questões para a sala de aula. *In*: OLIVEIRA, I.; SISS, A (org.). **População negra e educação escolar.** Niterói: Cadernos Penesb, 2006. p. 68-101.

LIU, B. Y. H.; JORDAN, R. C. The interrelationship and characteristic distribution of direct, diffuse and total solar radiation. **Solar energy**, Oxford, v. 4, n. 3, p. 1-19, 1960.

MACKAY, D. J. C. Bayesian interpolation. **Neural computation**, Cambridge, v. 4, n. 3, p. 415-447, 1992.

MAKRIDAKIS, S. G.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting methods and applications**. Hoboken: John Wiley & Sons, 1998.

MANTZARI, V. H.; MANTZARIS, D. H. Solar radiation: Cloudiness forecasting using a soft computing approach. **Artificial Intelligence Research**, El Segundo, v. 2, n. 1, p. 69-80, 2013.

MBINZA, P. **Produção de energia eléctrica em Angola cresceu para 6 319,43 megawatts em 2023**. 2023. Disponível em: <https://www.forbesafricalusofona.com/>. Acesso em: 30 abr. 2024.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, New York, v. 5, p. 115-133, 1943.

MELLIT, A.; PAVAN, A. M.; LUGHI, V. Short-term forecasting of power production in a large-scale photovoltaic plant. **Solar Energy**, Oxford, v. 105, p. 401-413, 2014.

MEZA, F.; VARAS, E. Estimation of mean monthly solar global radiation as a function of temperature. **Agricultural and Forest Meteorology**, Amsterdam, v. 100, n. 2-3, p. 231-241, 2000.

MFETOUM, I. M. *et al.* A multilayer perceptron neural network approach for optimizing solar irradiance forecasting in Central Africa with meteorological insights. **Scientific Reports**, London, v. 14, n. 1, p. 3572, 2024.

MILES, R. W. Photovoltaic solar cells: choice of materials and production methods. **Vacuum**, Oxford, v. 80, n. 10, p. 1090-1097, 2006.

MORDOR INTELLIGENCE. **Análise de tamanho e participação do mercado solar do Egito: tendências e previsões de crescimento**. 2024a. Disponível: <https://www.mordorintelligence.com/pt/industry-reports/egypt-solar-energy-market>. Acesso em: 3 jan. 2024.

MORDOR INTELLIGENCE. **Angola power EPC market size share analysis: tendências e previsões de crescimento**. 2024b. Disponível em: <https://www.mordorintelligence.com/pt/industry-reports/angola-power-epc-market>. Acesso em: 4 de jan. 2024.

MORDOR INTELLIGENCE. **Tamanho do Mercado de Energia Renovável da África do Sul**. 2024c. Disponível em: <https://www.mordorintelligence.com/pt/industry-reports/southern-africa-renewable-energy-market>. Acesso em: 3 jan. 2024.

MORIGGI, T.; LOH, G. V.; MARQUES, M. A. M. Product performance: A prediction model for compressive strength of composed cements. **IEEE Latin America Transactions**, Piscataway, v. 18, n. 03, p. 507-513, 2020.

OLIVEIRA, A. R. Redes neurais artificiais aplicadas na detecção, classificação e localização de defeitos em linhas de transmissão. UFJF, Juiz de Fora, 2005.

ØSTERGAARD, P. A. *et al.* Review and validation of EnergyPLAN. **Renewable and Sustainable Energy Reviews**, Oxford, v. 168, p. 112724, 2022.

PASCOAL, W. **Benguela vai ter duas centrais de energia solar**. 2021. Disponível em: <https://www.jornaldeangola.ao/>. Acesso em: 01 mai. 2024.

PEDRO BON, F. Redes neurais artificiais aplicadas à previsão de irradiância global horizontal no contexto de cidades energeticamente inteligentes. 2020. Dissertação (Mestrado) - Curso de Engenharia Urbana, Universidade Estadual de São Carlos, São Carlos, 2020.

PELLAND, S. *et al.* Photovoltaic and solar forecasting: state of the art. **IEA PVPS Task**, [S. l.], v. 14, n. 355, p. 1-36, 2013.

QAZI, A. *et al.* An artificial neural network for solar radiation prediction and solar system design: a systematic literature review. **Journal of Cleaner Production**, Amsterdam, v. 104, p. 1-12, 2015.

RENSHENG, C. *et al.* Estimation of horizontal diffuse solar radiation with measured daily data in China. **Renewable Energy**, Oxford, v. 29, n. 5, p. 717-726, 2004.

ROUTHIER, A. F.; HONSBURG, C. Using PV and thermal energy storage to decrease carbon dioxide emissions. *In: World Conference on Photovoltaic Energy Conversion; 45th IEEE PVSC; 28th PVSEC; 34th EU PVSEC, 7., 2018, Waikoloa Village. Anais [...]. Piscataway: IEEE, 2018. p. 1477-1480.*

SENGUPTA, M. *et al.* Best practices handbook for the collection and use of solar resource data for solar energy applications. Golden: NREL, 2021.

SHAH, S. *et al.* In situ transcription profiling of single cells reveals spatial organization of cells in the mouse hippocampus. **Neuron**, Cambridge, v. 92, n. 2, p. 342-357, 2016.

SHUVHO, M. B. A. *et al.* Prediction of solar irradiation and performance evaluation of grid connected solar 80KWp PV plant in Bangladesh. **Energy Reports**, Amsterdam, v. 5, p. 714-722, 2019.

SIGAUKE, C.; CHANDIWANA, E.; BERE, A. Spatio-temporal forecasting of global horizontal irradiance using Bayesian inference. **Applied Sciences**, Basel, v. 13, n. 1, p. 201, 2022.

SOLANKI, S. K.; KRIVOVA, N. A.; HAIGH, J. D. Solar irradiance variability and climate. **Annual Review of Astronomy and Astrophysics**. v. 51, p. 1-85, 2013.

SOLARGIS. Solar resource maps and GIS data for 200+ countries. África, 2020a. Disponível em: <https://solargis.com/resources/free-maps-and-gis-data?locality=africa>. Acesso em: 01 mar. 2023.

SOLARGIS. Solar resource maps and GIS data for 200+ countries. África do Sul, 2020b. Disponível em: <https://solargis.com/resources/free-maps-and-gis-data?locality=south-africa>. Acesso em: 01 mar. 2023.

SOLARGIS. Solar resource maps and GIS data for 200+ countries. Angola, 2020c. Disponível em: <https://solargis.com/resources/free-maps-and-gis-data?locality=angola>. Acesso em: 02 mar. 2023.

SOLARGIS. Solar resource maps and GIS data for 200+ countries. Egíto, 2020d. Disponível em: <https://solargis.com/resources/free-maps-and-gis-data?locality=egypt>. Acesso em: 02 mar. 2023.

TEIXEIRA JÚNIOR, L. A. *et al.* Redes neurais artificiais e decomposição Wavelet na previsão da radiação solar direta. *In: Congresso Latino-Iberoamericano de Investigación Operativa; Simpósio Brasileiro de Pesquisa Operacional*, 16., 44., 2012, Rio de Janeiro. **Anais [...]**. São José dos Campos: SOBRAPO, 2020, p. 1-9.

UNITED STATES OF AMERICA – USA. **Office of energy efficiency & renewable energy**. 2013. U.S. Department of energy. Solar Radiation Basics. 2013. Disponível em: <https://www.energy.gov/eere/solar/solar-radiation-basics>. Acesso em: 24 Jun. 2023.

VEISSID, N.; PEREIRA, E. B. Estimativa do albedo planetário empregando dados do experimento célula solar do satélite brasileiro SCD2. **Revista Brasileira de Geofísica**, Rio de Janeiro, v. 18, p. 25-38, 2000.

VISCONDI, G. F.; SOUZA, S. N. A. Solar irradiance prediction with machine learning algorithms: a brazilian case study on photovoltaic electricity generation. **Energies**, Basel, v. 14, n. 18, p. 1-15, 2021.

VOYANT, C. *et al.* Machine learning methods for solar radiation forecasting: a review. **Renewable Energy**, Oxford, v. 105, p.569-582, 2017.

WALLACE, J. M.; HOBBS, P. V. **Atmospheric science**: an introductory survey. Amsterdam: Elsevier, 2006.

WILLMOTT, C. J.; MATSUURA, K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. **Climate research**, Oldendorf, v. 30, n. 1, p. 79-82, 2005.

WORLD BANK. **About us**. 2022. Disponível em: <https://data.worldbank.org/about>. Acesso em: 24 Jun. 2023.

YADAV, A. K.; CHANDEL, S. S. Artificial neural network based prediction of solar radiation for Indian stations. **International Journal of Computer Applications**, New York, v. 50, n. 9, 2012.

YADAV, A. K.; CHANDEL, S. S. Solar radiation prediction using Artificial Neural Network techniques: a review. **Renewable and sustainable energy reviews**, Oxford, v. 33, p. 772-781, 2014.

YANG, D.; WU, E.; KLEISSL, J. Operational solar forecasting for the real-time market. **International Journal of Forecasting**, Amsterdam, v. 35, n. 4, p. 1499-1519, 2019.
ZAU, F. **Angola**: trilhos para o desenvolvimento. Lisboa: Universidade Aberta, 2002.