



CENTRO UNIVERSITÁRIO SENAI CIMATEC
Programa de Pós-Graduação em
Modelagem Computacional e Tecnologia Industrial

CARLOS EDUARDO MALAQUIAS FERNANDES

**USO DE INTELIGÊNCIA ARTIFICIAL E SOFTWARES DE
DIMENSIONAMENTO E SIMULAÇÃO PARA ANÁLISE DE
GERAÇÃO DE ENERGIA EM PLANTAS FOTOVOLTAICAS**

Salvador

2024

CARLOS EDUARDO MALAQUIAS FERNANDES

**USO DE INTELIGÊNCIA ARTIFICIAL E SOFTWARES DE
DIMENSIONAMENTO E SIMULAÇÃO PARA ANÁLISE DE
GERAÇÃO DE ENERGIA EM PLANTAS FOTOVOLTAICAS**

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem Computacional e Tecnologia Industrial do Centro Universitário SENAI CIMATEC como requisito parcial para a obtenção do título de Mestre em Modelagem Computacional e Tecnologia Industrial.
Orientador(a): Prof. Dr. Fernando Luiz Pellegrini Pessoa.
Coorientador(a): Prof. Dr. Edson Ricardo Calado Sabino.

Salvador

2024

Ficha catalográfica elaborada pela Biblioteca do Centro Universitário SENAI CIMATEC

F363u Fernandes, Carlos Eduardo Malaquias

Uso de inteligência artificial e softwares de dimensionamento e simulação para análise de geração de energia em plantas fotovoltaicas / Carlos Eduardo Malaquias Fernandes. – Salvador, 2024.

143 f. : il. color.

Orientador: Prof. Dr. Fernando Luiz Pellegrini Pessoa.

Coorientador: Prof. Dr. Edson Ricardo Calado Sabino.

Dissertação (Mestrado em Modelagem Computacional e Tecnologia Industrial) – Programa de Pós-Graduação, Centro Universitário SENAI CIMATEC, Salvador, 2024.

Inclui referências.

1. Energias solar. 2. Previsão meteorológica. 3. Produção energética. 4. Softwares fotovoltaicos. 5. Redes neurais. I. Centro Universitário SENAI CIMATEC. II. Pessoa, Fernando Luiz Pellegrini. III. Sabino, Edson Ricardo Calado. IV. Título.

CDD 006.3



CENTRO UNIVERSITÁRIO SENAI CIMATEC

Mestrado Acadêmico em Modelagem Computacional e Tecnologia Industrial

A Banca Examinadora, constituída pelos professores abaixo listados, aprova a Defesa de Mestrado, intitulada “**USO DE INTELIGÊNCIA ARTIFICIAL E SOFTWARES DE DIMENSIONAMENTO E SIMULAÇÃO EM PLANTAS FOTOVOLTAICAS**” apresentada no dia 05 de setembro de 2024, como parte dos requisitos necessários para a obtenção do Título de Mestre em Modelagem Computacional e Tecnologia Industrial.

Orientador: **Prof. Dr. Fernando Luiz Pellegrini Pessoa**
SENAI CIMATEC

Coorientador: **Prof. Dr. Edson Ricardo Calado Sabino**
CHESF

Membro Interno: **Prof. Dr. Oberdan Rocha Pinheiro**
SENAI CIMATEC

Membro Externo: **Prof. Dr. Manoel Henrique de Oliveira Pedrosa Filho**
IFPE

*Dedico este trabalho aos meus pais,
Jaciara Malaquias e Waldecke Fernandes
(in memoriam).*

AGRADECIMENTOS

Agradeço primeiro a Deus por ter me mantido na trilha certa durante este projeto de pesquisa, estudos e etapas do mestrado com saúde e forças para chegar até o final.

Sou grato à minha família pelo apoio que sempre me deram. Com agradecimento em especial aos meus pais, Jaciara Malaquias e Waldecke Fernandes, que sempre estiveram ao meu lado me apoiando ao longo de toda a minha trajetória e pela torcida fiel. Não posso esquecer de Luiz Paulo, Maria Eduarda, Ana Cláudia e Pedro Henrique, por quem tenho grande carinho.

À minha noiva, Martinha, pela compreensão, apoio e paciência demonstrada durante o período do projeto. E por ser a melhor ouvinte durante todo o período do mestrado, obrigado pelas longas conversas e por ser parceira em mais essa etapa na minha vida.

Deixo um agradecimento especial ao meu orientador, Prof. Dr. Fernando Luiz Pellegrini Pessoa e ao Coorientador Prof. Dr. Edson Ricardo Calado Sabino, pelo incentivo, pela dedicação do seu escasso e valioso tempo ao meu projeto de pesquisa. Também quero agradecer ao Centro Universitário Senai Cimatec e a todos os professores do meu curso pela elevada qualidade do ensino oferecido. Em especial ao nosso coordenador geral, Prof. Alex Álisson Bandeira Santos.

Obrigado a todos(a) os(a) graduandos(a) da nossa turma de mestrado: Hugo Salvador, Elisabete Barreto, Pedro Filho, Henrique Mergulhão, Giorgio Limeira, Carlos Henrique e Tiago Maritan.

Aos amigos de trabalho e família RCD – Eletrobras - Chesf, em especial a Marcelo Ferraz, Thiago Maciel, Júnior Feitosa e Tiago Barros.

Agradeço o papel da Eletrobras - Chesf, na conclusão deste mestrado e em especial aos srs. Fábio Lopes Alves (Ex-presidente Eletrobras-Chesf), José Bione de Melo Filho, Frederico Lins, Valdeckson Burgo, Márcio Carvalho, equipes Chesf Recife II, Messias, Casa Nova e CRESP Petrolina.

Colégio Severa Romana, Souza Veras, Colégio Jefferson, Liceu de Artes e Ofícios de Pernambuco, Senai, Universidade Estadual do Ceará, Universidade Federal do Ceará, UFRPE, Uninassau, IFPE, Estácio e Senai Cimatec...Um passo de cada vez na trajetória, boas lembranças, conhecimento e aprendizado.

A todos(as), meus sinceros agradecimentos!

RESUMO

O estudo acadêmico tem como foco mostrar o uso dos softwares de dimensionamento e simulação como o PV*SOL e PVsyst para análise de dados reais medidos de usinas solares em Petrolina (PE) e Messias (AL), em comparação com dados meteorológicos de estações próximas. O objetivo é avaliar a precisão e a utilidade dessas ferramentas de software para implementação, teste e monitoramento de usinas solares. Os fatores considerados para a concepção do projeto fotovoltaico incluem dados meteorológicos, sombreamento do local, orientação do módulo, posicionamento geográfico, perdas de temperatura, componentes elétricos, equipamentos e mudanças climáticas. Foi realizada uma análise abrangendo janeiro a dezembro de 2023, com intervalos de hora em hora com base em dados meteorológicos confiáveis. As ferramentas de software auxiliam no dimensionamento do sistema considerando esses fatores, variáveis adicionais e fazendo previsões. É crucial que estas ferramentas produzam resultados precisos para prever a produção de energia que corresponda próxima à produção real. A qualidade dos bancos de dados meteorológicos e dos modelos matemáticos utilizados também impacta o desempenho dos softwares, com esforços feitos para filtrar, qualificar e catalogar fontes de dados. Os resultados de produção mostraram 3796 MWh/ano para a Usina Petrolina, 1171 MWh/ano para a Usina Messias II, com variações de - 0,79 % a 8,89% observadas entre os dados medidos e estimados. E uma correlação para esses mesmos dados variando de 0,77 a 0,93 e uma faixa de erro médio percentual de 5,46% a 10,57% para Petrolina e 10,18% a 24,06% para Messias. Juntamente com a análise de software, o estudo incorpora o uso do Neural Designer, um software de rede neural baseado em aprendizado de máquina, para análises comparativas adicionais nas mesmas usinas solares. As descobertas sugerem insights sobre as características da planta, alinhamento da produção de energia com as previsões do software e análise do projeto. Os resultados foram comparados com estudos similares e com a literatura já existente sobre o assunto, para corroborar com a proposta do estudo.

Palavras-chave: Energia Solar; Previsão Meteorológica; Produção Energética; Softwares Fotovoltaicos; Redes Neurais.

ABSTRACT

USE OF ARTIFICIAL INTELLIGENCE AND SIZING AND SIMULATION SOFTWARE FOR ANALYZING ENERGY GENERATION IN PHOTOVOLTAIC PLANTS

The academic study focuses on demonstrating the use of sizing and simulation software such as PV*SOL and PVsyst for analyzing real data measured from solar plants in Petrolina (PE) and Messias (AL), in comparison with meteorological data from nearby stations. The objective is to evaluate the accuracy and usefulness of these software tools for implementing, testing and monitoring solar plants. Factors considered for designing the PV project include meteorological data, site shading, module orientation, geographic positioning, temperature losses, electrical components, equipment and climate changes. An analysis was performed covering January to December 2023, with hourly intervals based on reliable meteorological data. The software tools assist in sizing the system by considering these factors, additional variables and making predictions. It is crucial that these tools produce accurate results to predict energy production that closely matches actual production. The quality of the meteorological databases and mathematical models used also impacts the performance of the software, with efforts made to filter, qualify and catalog data sources. The production results showed 3796 MWh/year for Usina Petrolina, 1171 MWh/year for Usina Messias II, with variations of -0,79% to 8,89% observed between the measured and estimated data. And a correlation for these same data ranging from 0,77 to 0,93 and a mean percentage error range of 5,46% to 10,57% for Petrolina and 10,18% to 24,06% for Messias. Along with the software analysis, the study incorporates the use of Neural Designer, a machine learning-based neural network software, for additional comparative analysis on the same solar plants. The findings suggest insights into plant characteristics, alignment of energy production with software predictions, and design analysis. The results were compared with similar studies and with existing literature on the subject, to corroborate the study proposal.

Keywords: Solar energy; Weather Forecast; Energy Production; Photovoltaic Software; Neural networks.

LISTA DE FIGURAS

Figura 1 - Total Instalado por Tipo de Fonte Energética em 2023.	21
Figura 2 - Ilustra as Definições de Ângulos Azimutal, Zenital e Altura Solar	27
Figura 3 - Tipos de Radiação Solar.....	28
Figura 4 - Influência da Radiação Solar na Operação do Módulo Fotovoltaico.....	29
Figura 5 - Comportamento Médio da Irradiância de Acordo com o Clima.....	30
Figura 6 - Total Diário de Irradiação no Plano Inclinado na Latitude - Média Anual.	31
Figura 7 - Linha do tempo da Energia Solar.....	35
Figura 8 - Tipos de Sistemas Fotovoltaicos.....	37
Figura 9 - Esquema do Efeito Fotovoltaico no Átomo de Silício.....	40
Figura 10 – Imagens dos tipos de células Fotovoltaicas.	41
Figura 11 - Heliógrafo.....	43
Figura 12 - Actinógrafo.....	43
Figura 13 - Piranômetro.....	43
Figura 14 - Pireliômetro	43
Figura 15 - Representação de um Neurônio Artificial.....	44
Figura 16 - Algumas das mais utilizadas funções de ativação em RNAs.....	45
Figura 17 - Exemplo de Rede Neural Artificial do tipo MLP.....	47
Figura 18 - Amostra de uma das telas do PV*SOL.....	50
Figura 19 - Amostra de uma das telas do PVsyst.....	51
Figura 20 - Modelo Utilizado pelo Neural Designer.....	52
Figura 21 - Funcionalidades Neural Designer.....	52
Figura 22 - Ciclo Neural Designer.....	53
Figura 23 - Exemplo de Rede Neural.....	53
Figura 24 - Modelo Rede Neural.....	58
Figura 25 - Modelo de entradas e saídas do projeto	63
Figura 26 - Torre Climatológica Eletrobras - Chesf.....	64
Figura 27 - Mapa Estações INMET.....	65
Figura 28 - Estação modelo INMET.....	66
Figura 29 - Localização Planta Fotovoltaica Messias.....	72
Figura 30 - Localização Planta Fotovoltaica Petrolina.....	74
Figura 31 - Gráfico Dispersão Rad. Medidas x Estimadas CRESP Petrolina.....	84
Figura 32 - Comparativo Medição Real x Medição Estimada Messias II (kWh/m ² /ano) .	86

Figura 34 - Gráfico Dispersão Rad. Medidas x Estimadas Messias II (kWh/m ²).	87
Figura 35 - Produções Normalizadas (por kWp instalado): Pot. Nominal 2508 kWp.	88
Figura 36 - Performance Ratio (PR) da Usina CRESP, em Petrolina.	89
Figura 37 - Produções normalizadas (por kWp instalado): Pot. Nominal 877 kWp. ..	91
Figura 38 - Performance Ratio (PR) da Usina, em Messias.....	92
Figura 39 - Vista Planta Petrolina no PV*SOL.....	94
Figura 40 - Vista Planta Messias II no PV*SOL.....	96
Figura 41 - Correlação Radiação x Entradas em Petrolina	98
Figura 42 – Radiação Estimada x Medida - Bondade do Ajuste CRESP Petrolina. ..	99
Figura 43 - Correlação Radiação x Entradas em Messias II	101
Figura 44 - Radiação Estimada x Medida - Bondade do Ajuste Messias II.	101
Figura 45 - Gráfico da Energia nos Softwares na Planta Petrolina em (kWh).	104
Figura 46 - Gráfico da Energia nos Softwares na Planta Messias II em (kWh).	106

LISTA DE TABELAS

Tabela 1 - Tipo de Fonte de Energia - Crescimento Oferta Interna em (MW).....	19
Tabela 2 - Escolha do Ângulo de Inclinação do Módulo.....	26
Tabela 3 - Tabela com Irradiações Médias em Petrolina.	33
Tabela 4 - Tabela com Irradiações Médias em Messias.	34
Tabela 5 - Quadro de Perceptrons	57
Tabela 6 - Quadro de Amostras.	57
Tabela 7 - Equipamentos Presentes na Planta Fotovoltaica.	65
Tabela 8 - Tabela Geral de Valores Meteorológicos das duas Localidades.....	67
Tabela 9 - Informações Geoclimáticas nas Plantas Fotovoltaicas.	67
Tabela 10 - Distância Estação - Planta e Período estudado.	68
Tabela 11 - Coeficientes mensais no modelo Angström-Prescott e de determinação para Messias e Petrolina	71
Tabela 12 - Configuração do Sistema Fotovoltaico em Messias II (AL)	72
Tabela 13 - Configuração do Sistema Fotovoltaico CRESP Petrolina (PE).	73
Tabela 14 - Interpretação dos Coeficientes de Correlação de Pearson.	78
Tabela 15 - Tipos de Perdas e valores utilizados como referência	81
Tabela 16 - Energia Gerada Anualmente Petrolina.....	82
Tabela 17 - Comparativo Produção Energia Estimada x Medida em Petrolina (kWh/ano).....	82
Tabela 18 - Métricas Estatísticas Petrolina.	83
Tabela 19 - Coef. Correlação e métricas de Erro do modelo Determinístico para Petrolina.	83
Tabela 20 - Energia Gerada Anualmente Messias II.....	85
Tabela 21 - Comparativo produção energia estimada x Medida em Messias II (kWh/m ² /ano).....	85
Tabela 22 - Coef. Correlação e métricas de Erro do modelo Determinístico para Messias II.....	86
Tabela 23 - Métricas Estatísticas Messias II.	87
Tabela 24 - Balanços e Resultados Principais Petrolina.	88
Tabela 25 - Coef. Correlação e métricas de Erro do modelo PVsyst para Petrolina.	90
Tabela 26 – Métricas Estatísticas Petrolina PVsyst.	90
Tabela 27 - Balanços e resultados principais Messias II.....	91
Tabela 28 - Coef. Correlação e métricas de Erro do modelo PVsyst para Messias.	93

Tabela 29 – Métricas Estatísticas Petrolina PVsyst Messias II em (kWh/m ²).....	93
Tabela 30 - Energia Mensal Estimada via PV*SOL para a Planta FV de Petrolina...	94
Tabela 31 – Coef. Correlação e métricas de Erro do PV*SOL para Petrolina.....	95
Tabela 32 – Métricas Estatísticas Petrolina PV*SOL.	95
Tabela 33 - Energia Mensal Estimada via PV*SOL para a Planta FV de Messias....	96
Tabela 34 - Métricas Estatísticas Messias II PV*SOL.	97
Tabela 35 - Coef. Correlação e métricas de Erro do PV*SOL para Messias.....	97
Tabela 36 - Dados Gerais Neural Designer Planta Petrolina.	98
Tabela 37 - Coef. Correlação e métricas de Erro do N. Designer CRESP Petrolina.	99
Tabela 38 - Tabela de Erros de Teste CRESP Petrolina.....	100
Tabela 39 - Erros do modelo para CRESP Petrolina.	100
Tabela 40 - Dados Gerais Neural Designer Planta Messias II.	100
Tabela 41 - Coef. Correlação e métricas de Erro do N. Designer Messias II.	102
Tabela 42 - Tabela de Erros de Teste Messias II.....	102
Tabela 43 - Erros do modelo para Messias II.....	102
Tabela 44 - Resultados da Energia Produzida no modelo determinístico e nos Softwares e suas Porcentagens para Petrolina.....	103
Tabela 45 - Resultados da Energia Produzida no modelo determinístico e nos Softwares e suas Porcentagens para Messias II.....	105
Tabela 46 - Erros de métricas estatísticas geradas utilizando o Neural Designer...	108
Tabela 47 - Quadro de comparação dos estudos	109

LISTA DE SIGLAS E ABREVIATURAS

AC - Corrente Alternada;

ANEEL - Agência Nacional de Energia Elétrica;

a-Si - Silício Amorfo;

C - Unidade de temperatura em graus Celsius, precedido de (°);

CC - Corrente Contínua;

CdTe - Telureto de cádmio;

CEPEL - Centro de Pesquisas de Energia Elétrica;

CGH - Centrais Geradoras Hidrelétricas;

Chesf - Companhia Hidro Elétrica do São Francisco;

Cresesb - Centro de Referência para Energia Solar e Eólica Sérgio Brito;

CIGS - Seleneto de Cobre Gálio e Índio;

CSV - Valores Separados por Vírgula;

DHI - Irradiância Difusa Horizontal;

DNI - Irradiância Direta Normal;

EOL - Eólica;

ESMAP - Programa de Assistência à Gestão do Setor Energético;

FV - Fotovoltaica;

GFV - Geração Fotovoltaica;

GHI - Irradiância Global Horizontal;

GW - Representa uma medida de potência equivalente a mil milhões de Watts (W)

hPa - Hectopascal, unidade de medida barométrica;

HSP - Hora de Sol Pleno ou Hora de Sol de Pico;

INMET - Instituto Nacional de Meteorologia;

INPE - Instituto Nacional de Pesquisas Espaciais;

J - Joule é a unidade tradicionalmente usada para medir energia mecânica, também utilizada para medir energia térmica;

Km² - Unidade de área;

KT - Índice de Claridade;

kV - Kilovolt;

kWh - Kilowatt-hora;

Labmet - Laboratório de Meteorologia;

LABREN - Laboratório de Modelagem e Estudos de Recursos Renováveis de Energia;

LAT - Irradiação global na inclinação da latitude local;

LID - Ligth Induced Degradation (Degradação induzida pela luz);

LSTM - Long short-term memory

MCTI - Ministério da Ciência, Tecnologia e Inovação;

MCTI - Ministério da Ciência, Tecnologia e Inovação;

MJ/m² - Mega Joule por metro quadrado;

MLP - Multi Layer Perceptron;

Mm - Unidade de medida de precipitação;

MMGD - Sigla para micro e minigeração distribuída que são pequenas centrais de geração de energia elétrica locais por meio de fontes renováveis ou cogeração qualificada;

MPPT - Rastreamento de ponto de potência máximo (Maximum Power Point Tracking);

MTEP - Unidade de medida de energia (106 toneladas equivalente de petróleo);

MW - Representa uma medida de potência equivalente a um milhão de Watts (W);

ONS - Operador Nacional do Sistema Elétrico;

PAR - Irradiação fotossinteticamente ativa, do inglês "*Photosynthetically Active Radiation*";

PCH - Pequenas Centrais Hidrelétricas;

PTEC - Potência Total de Energia Contínua;

RI - Irradiância Refletida;

RNA – Rede Neural Artificial;

S.D. - Sem data;

SIGA - Sistema de Informações de Geração da ANEEL;

SIN - Sistema Integrado Nacional;

SONDA - Sistema de Organização Nacional de Dados Ambientais;

TW - Representa uma medida de potência equivalente a um trilhão de Watts (W);

UFV - Usina Fotovoltaica;

UHE - Usinas Hidrelétricas;

UNIVASF - Universidade Federal do Vale do São Francisco;

UTE - Usinas Termoelétricas;

UTN - Usina Termonuclear;

W/m² - Watts por metro quadrado;

LISTA DE SÍMBOLOS

α - Parâmetro e/ou coeficiente;

δ - Ângulo Solar;

ε - Erro Aleatório;

f_{pv} - fator de perdas

φ - Latitude;

μ - Unidade de medida equivalente a 10^{-6} metros;

ω_s - Ângulo do pôr do Sol;

θ_z - o ângulo zenital.

π - Pi;

Σ - Somatório;

SUMÁRIO

1 INTRODUÇÃO	19
1.1 OBJETIVOS.....	23
1.1.1 OBJETIVO GERAL.....	23
1.1.2 OBJETIVOS ESPECÍFICOS	23
1.2 ORGANIZAÇÃO DO DOCUMENTO.....	24
2 REVISÃO DA LITERATURA	25
2.1 RADIAÇÃO SOLAR.....	25
2.1.1 PRINCIPAIS FATORES DE INFLUÊNCIA NA GERAÇÃO DE ENERGIA FV ..	29
2.1.2 ÍNDICE DE CLARIDADE KT	30
2.1.3 RADIAÇÃO SOLAR NO BRASIL, NORDESTE E NAS PLANTAS ESTUDADAS.	31
2.2 ENERGIA SOLAR FOTOVOLTAICA.....	34
2.2.1 TIPOS DE SISTEMAS FOTOVOLTAICOS.....	36
2.2.2 SISTEMAS CONECTADOS À REDE – GRID TIE	36
2.2.3 SISTEMAS OFF-GRID	36
2.2.4 SISTEMAS HÍBRIDOS	37
2.2.5 USINAS SOLARES.....	37
2.2.6 COMPONENTES DE UMA PLANTA SOLAR	38
2.3 CÉLULA FOTOVOLTAICA E SUA EFICIÊNCIA	39
2.3.1 TIPOS DE PAINÉIS FOTOVOLTAICOS	41
2.4 EQUIPAMENTOS UTILIZADOS NA COLETA DOS DADOS METEOROLÓGICOS	42
2.5 REDES NEURAIS	44
2.6 ESTIMATIVAS DE PRODUÇÃO DE USINAS FOTOVOLTAICAS.....	47
2.7 SOFTWARES DE DIMENSIONAMENTO E SIMULAÇÃO.....	49
2.7.1 SOFTWARE PV*SOL	49
2.7.2 SOFTWARE PVSYSYD	51
2.7.3 NEURAL DESIGNER.....	52
2.8 ESTUDOS SIMILARES.....	60
3 MATERIAIS E MÉTODOS	63
3.1 FONTES DE DADOS METEOROLÓGICOS	64
3.1.1 ESTAÇÃO CLIMATOLÓGICA PRESENTE NAS PLANTAS SOLARES.....	64
3.1.2 INMET.....	65
3.1.3 LABMET	66

3.1.4 DADOS METEOROLÓGICOS DOS LOCAIS OBSERVADOS	67
3.2 PERÍODO ANALISADO, QUALIFICAÇÃO E FILTROS DOS DADOS.....	67
3.3 DETALHES DAS PLANTAS ANALISADAS.....	71
3.4 MÉTRICAS ESTATÍSTICAS DE COMPARAÇÃO UTILIZADAS.....	74
3.4.1 MÉDIAS.....	75
3.4.2 VARIÂNCIA E DESVIO PADRÃO AMOSTRAL.....	75
3.4.3 MEDIANA.....	75
3.5 MÉTRICAS R, MAE, MAPE, MSE E RMSE	75
3.5.1 ERRO MÉDIO ABSOLUTO.....	76
3.5.2 ERRO PERCENTUAL ABSOLUTO MÉDIO	76
3.5.3 ERRO QUADRÁTICO MÉDIO.....	77
3.5.4 RAIZ DO ERRO QUADRÁTICO MÉDIO	77
3.5.5 CORRELAÇÃO DE PEARSON.....	78
3.6 INTERVALO DE CONFIANÇA.....	79
3.7 MODELO DETERMINÍSTICO DE GERAÇÃO DE ENERGIA FOTOVOLTAICA.....	79
3.8 PERDAS DE UM SISTEMA FOTOVOLTAICO.....	80
4 RESULTADOS E DISCUSSÃO	82
4.1 MODELO DETERMINÍSTICO PLANTA FOTOVOLTAICA CRESP – PETROLINA (PE).....	82
4.2 MODELO DETERMINÍSTICO PLANTA FOTOVOLTAICA MESSIAS II (AL).....	84
4.3 RESULTADOS OBTIDOS COM O SOFTWARE PVSYST.....	87
4.3.1 DADOS GERAIS - PLANTA FV CRESP PETROLINA (PE).....	87
4.3.2 DADOS GERAIS - PLANTA FV MESSIAS II.....	91
4.4 RESULTADOS OBTIDOS COM O SOFTWARE PV*SOL	93
4.4.1 DADOS GERAIS – PLANTA FV CRESP PETROLINA.....	94
4.4.2 DADOS GERAIS - PLANTA FV MESSIAS II.....	96
4.5 RESULTADOS OBTIDOS COM O SOFTWARE NEURAL DESIGNER.....	98
4.5.1 DADOS GERAIS – PLANTA FV CRESP PETROLINA.....	98
4.5.2 DADOS GERAIS - PLANTA FV MESSIAS II.....	100
4.6 PRODUÇÃO ENERGÉTICA NOS SOFTWARES, SAÍDA DE POTÊNCIA E ESTUDOS SIMILARES.....	103
4.6.1 PLANTA FOTOVOLTAICA CRESP PETROLINA (PE).....	103
4.6.2 PLANTA FOTOVOLTAICA MESSIAS II (AL)	105

4.6.3 QUADRO COMPARATIVO INDICADORES ESTATÍSTICOS.....	108
4.6.4 QUADRO COMPARATIVO ENTRE OS ESTUDOS SIMILARES ANALISADOS E O PRESENTE ESTUDO.....	109
5 CONCLUSÕES	110
REFERÊNCIAS	112
ANEXOS	121

1 INTRODUÇÃO

Embora a pandemia tenha abrandado o consumo, a demanda por eletricidade continua a crescer ao longo do tempo desde então. Dados do ONS mostram que o consumo médio diário de energia do Brasil em 2023 atingiu 75,7 GWh e até fevereiro de 2024, o consumo médio de energia foi de cerca de 83,5 GWh. O consumo de energia bateu recordes consecutivos no Brasil, em razão da elevação da temperatura verificada em grande parte do país e as constantes ondas de calor. Segundo o Operador Nacional do Sistema Elétrico (ONS) (ONS, 2024, p.1), foi registrado na terça-feira 14/11/2023, pelo segundo dia consecutivo, um novo recorde na demanda instantânea de carga do Sistema Interligado Nacional (SIN), com o patamar de 101.475 MW às 14h20.

O Brasil é um dos países com maior potencial de instalação e geração de energia do mundo em energia fotovoltaica, devido à sua elevada incidência solar e vasta área. Assim, essa fonte de energia sustentável tem potencial para reduzir a dependência do Brasil de hidrelétricas e termoeletricas.

O crescimento da energia fotovoltaica distribuída, que permite, por exemplo, ao usuário instalar módulos em sua residência, comércios e indústrias, reduzindo assim os custos financeiros que seriam esperados no pagamento de faturas do serviço de energia e em alguns casos até um rendimento financeiro. Tomando 2021 e 2022 como exemplo, esse tipo de fonte energética apresentou um aumento significativo de 82,4%, conforme Tabela 1.

Tabela 1 - Tipo de Fonte de Energia - Crescimento Oferta Interna em (MW).

Fonte	2021	2022	▲ %22/21
Hidrelétrica	109,413	109,807	0,4%
Térmica	44,982	46,440	3,2%
Nuclear	1,990	1,990	0,0%
Eólica	20,780	23,761	14,3%
Solar	13,404	24,453	82,4%
Capacidade Disponível MW	190,574	206,451	8,3%

Fonte: ANEEL, (2024).

Segundo o Balanço Energético Nacional – BEN (2022), a oferta interna de energia em 2022, (total de energia disponibilizada no país) atingiu 303,1 Mtep, registrando um recuo de 0,03% em relação ao ano anterior. A participação de renováveis na matriz energética foi marcada pelo aumento da oferta de energia hidráulica, associada à melhoria do regime hídrico e à redução do uso das usinas termelétricas a partir de combustíveis fósseis como gás natural, carvão e derivados de petróleo.

Adicionalmente, associado à expansão da fonte hidráulica, o incremento das fontes eólica e solar na geração de energia elétrica, assim como de outras renováveis como lixo, biogás e outras biomassas, contribuíram para que a matriz energética brasileira se mantivesse em um patamar renovável de 47,4%, muito superior ao observado no resto do mundo.

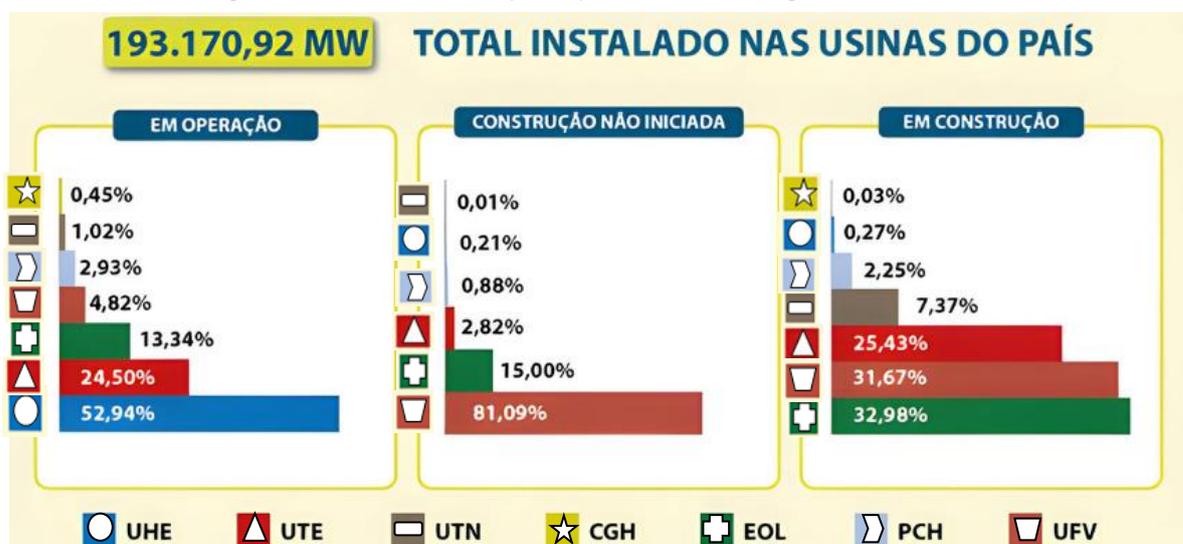
Conforme estudos da (EPE, 2024, p. 6), no caso da energia elétrica, verificou-se crescimento na oferta interna de 10,9 TWh (+1,6%) em relação a 2021.

A matriz elétrica brasileira, fechou o mês de maio de 2023 com uma expansão de 4.610,20 megawatts (MW). Até 31 de maio, a Agência Nacional de Energia Elétrica (ANEEL) registrou a entrada em operação comercial de 144 usinas, sendo 62 eólicas (2.006,9 MW), 55 solares fotovoltaicas (2.033,2 MW), 19 termelétricas (476,7 MW), cinco pequenas centrais hidrelétricas (82,1 MW) e três centrais geradoras hidrelétricas (11,4 MW). Plantas solares e eólicas representam, juntas, 87,6% da capacidade instalada no ano.

As usinas com operação iniciada em 2023, estão localizadas em 19 estados das cinco regiões brasileiras. Em ordem decrescente, apresentam maiores resultados até o momento os seguintes estados: Bahia (1.559,7 MW), Minas Gerais (1.107,8 MW), Rio Grande do Norte (798,9 MW) e Piauí (358,9 MW). No recorte apenas para o mês de maio, a Bahia obteve o maior salto, com 992,6 MW, provenientes da entrada em operação da Complexo Futura.

No que se refere a capacidade instalada Figura 1, o Brasil somou 193.170,92 MW de potência fiscalizada até 31 de maio de 2023, de acordo com dados do Sistema de Informações de Geração da ANEEL, o SIGA, atualizado diariamente com dados de usinas em operação e de empreendimentos outorgados em fase de construção. Desse total em operação, ainda conforme o SIGA, 83,6% das usinas são consideradas renováveis. Em dezembro de 2024 atingiu o patamar de 84,81%.

Figura 1 - Total Instalado por Tipo de Fonte Energética em 2023.



Fonte: ANEEL, (2024) Adaptado pelo autor.

Legenda:

- UHE - Usinas Hidrelétricas
- UTE – Usinas Termoelétricas
- EOL – Eólicas
- UFV – Usina Fotovoltaica
- UTN – Usina Termonuclear
- CGH – Centrais Geradoras Hidrelétricas
- PCH – Pequenas Centrais Hidrelétricas

A geração fotovoltaica (GFV) é caracterizada por uma intermitência, que é inerente ao recurso solar e que precisa ser tratada para garantir a confiabilidade do fornecimento de eletricidade à rede (Carneiro *et al.*, 2021). As previsões precisas da GFV podem reduzir o custo líquido da geração (Lima *et al.*, 2020, p. 195) e os impactos sobre a segurança da rede.

Nos mercados de desequilíbrios de energia, a previsão solar monitorada está apresentando benefícios, trazendo redução na necessidade de recursos de backup e pode contribuir para a manutenção do equilíbrio entre a demanda e a oferta de energia (Wang *et al.*, 2019).

Os métodos de previsão solar aprendem o comportamento das séries do recurso solar ou da GFV e implementam o conhecimento adquirido para prever valores futuros, usando dados anteriores que podem vir da própria série ou de outras séries que influenciam em seu comportamento (Carneiro *et al.*, 2021). De acordo com (Antonanzas *et al.*, 2016), existem vários métodos aplicáveis à previsão solar, que podem ser classificados em diferentes abordagens (métodos estatísticos, métodos de aprendizado de máquina, métodos físicos e os métodos híbridos).

De acordo com (MertYagli *et al.*, 2019), os modelos baseados em aprendizado de máquina produziram uma grande quantidade de artigos na área de previsão solar nos últimos anos e se apresentam como uma abordagem popular para a previsão solar em horizonte horário.

As plantas fotovoltaicas apresentam perdas esperadas durante o período de operação que afetam o seu desempenho. Sendo as mais comuns, as perdas ôhmicas nos cabamentos (Nascimento e Ferreira, 2018), a sujeira, a degradação induzida pela luz (LID - *Ligth Induced Degradation*), (Silva *et al.* 2018), a degradação ao longo da vida útil dos módulos esperada de menos de 1% por ano (Cassini *et al.* 2018) e aquelas resultantes da temperatura de operação dos módulos.

No inversor, as perdas ocorrem durante a conversão de energia de Corrente Contínua (CC) para Corrente Alternada (AC) (Nascimento e Ferreira, 2018). Dessa forma, as instalações fotovoltaicas necessitam que a sua energia produzida seja verificada periodicamente, para detectar reduções abruptas de eficiência, relacionadas às perdas esperadas, cuja consequência é o impacto na quantidade de energia injetada na rede pela planta. Esta quantidade também sofre influência do clima da localidade, ou seja, um ano muito chuvoso provocará redução da energia produzida, o que necessariamente não foi causada pelo aumento das perdas. A energia gerada por um sistema FV varia de acordo com diversos parâmetros, como a radiação solar incidente no plano dos módulos FV e a temperatura ambiente (Camargo *et al.*, 2019). Dessa forma, a medição precisa desses dados nas proximidades do local de instalação do sistema é muito importante para obter uma previsão mais assertiva do desempenho de projetos FV com intuito de ter a garantia do retorno do investimento inicial (Murat Ates; Singh, 2021).

Levando em consideração a importância de ter métricas para uma melhoria da eficiência, monitoramento, comparações e previsões em plantas solares. Utilizar a inteligência artificial, métodos estatísticos e computacionais de comparação, para otimizar e maximizar os resultados de uso e produção energética de plantas FV, tanto como suas peculiaridades de previsão adiante, localização, melhor reaproveitamento de local e distribuição. Analisar resultados obtidos com valores reais e estimar a porcentagem de acerto. Criando uma base de dados com os diferentes cenários e tipos de planta. A utilização de softwares com arquitetura própria para tal função permite analisar dados, quer seja via softwares de dimensionamento e supervisão de plantas FV ou inteligência artificial.

O estudo analisa um período de um ano de dados e traz informações importantes que podem, por exemplo, ajudar a demonstrar quais cidades se tornarão mais produtivas ao longo do tempo e, pelas análises dos softwares, quais meses deverão gerar mais energia. Pode orientar os consumidores e empresas na escolha de quando e onde investir na instalação de usinas de energia solar e sistemas fotovoltaicos. As práticas abordadas servem também como um modelo para utilização em outros períodos e outras plantas FV.

1.1 Objetivos

1.1.1 Objetivo Geral

Como objetivo geral de comparar a produção de energia elétrica medida com a estimada por softwares de dimensionamento, simulação e de redes neurais com ênfase em plantas fotovoltaicas. Paralelo a isso, conforme os resultados obtidos, comparar a precisão e proximidade dos resultados desses softwares com os resultados medidos na usina fotovoltaica instalada e outros estudos similares e utilizar métricas estatísticas e matemáticas para gerar um panorama do projeto estudado, sua entrega energética, possibilidades de melhorias e atestar se a planta solar em estudo está conforme o projeto e seus resultados de produção energética estão de acordo com parâmetros de teste e dimensionamento dos softwares analisados.

1.1.2 Objetivos Específicos

- Elaborar um levantamento de dados do Instituto Nacional de Meteorologia (INMET), Labmet, Cresesb, estação presente na planta solar, Atlas solarimétrico entre outras fontes meteorológicas disponíveis;
- Realizar levantamento, tratamento e qualificação dos dados coletados para as medidas de radiação solar, temperatura ambiente, umidade relativa, nebulosidade, velocidade do vento e outras que possam ser úteis para o estudo, para duas cidades da região nordeste onde se encontram plantas solares Eletrobras Chesf: Messias (Alagoas) e Petrolina (Pernambuco);
- Estimar métricas estatísticas associadas aos dados obtidos;
- Aplicar a análise das métricas estimadas em comparação com as métricas fornecidas pelas plantas solares e comparar indicadores estatísticos e computacionais medidos com os dados estimados;
- Estimar a produção de energia média diária e anual;
- Analisar os resultados obtidos no estudo, comparando com estudos similares.

1.2 Organização do Documento

No **primeiro capítulo**, são apresentadas uma introdução, o objetivo geral, objetivos específicos e a organização da dissertação, já no **segundo capítulo**, é apresentada uma revisão da literatura destacando o aproveitamento da energia solar para a produção de energia e o papel de softwares e da inteligência artificial como instrumento de apoio e de análise e estudos similares na área, na sequência o **terceiro capítulo**, são desenvolvidos o modelo matemático e estatístico, no **quarto capítulo**, são apresentados e analisados os principais resultados e finalizando no **último capítulo**, apresentam-se as principais conclusões resultantes deste trabalho, são discutidos os resultados, comentados resultados em outros estudos similares e apresentadas sugestões.

2 REVISÃO DA LITERATURA

2.1 Radiação Solar

O Sol é uma estrela que emite uma quantidade de energia em direção à Terra. Segundo Marques e Delvizio, (2020), a quantidade de energia solar que incide na superfície da Terra é de até $1,5 \times 10^{18}$ kWh/ano, valor que representa aproximadamente 1% da energia total consumida pela Terra em um ano, este fato demonstra a importância do Sol como fonte de energia e calor.

A radiação solar que atinge a superfície da atmosfera terrestre superior, é de cerca de 1367 W/m^2 , levando em conta o fato que apenas metade da Terra está voltada para o Sol para efeitos de cálculo.

A quantidade média de energia do Sol absorvida pela Terra é cerca de 70% da energia incidente, podendo ser usada nas usinas solares térmicas ou módulos fotovoltaicos. A irradiância solar total é a potência máxima fornecida à superfície da Terra, assumindo que o caminho da luz incidente é perpendicular a essa superfície. Devido ao fato da Terra ser uma esfera, apenas lugares próximos ao equador estão próximos desse ângulo de incidência solar perpendicular. Em todos os outros locais da Terra, a luz solar incidente depende de algum ângulo. Com esse ângulo decrescente, a irradiância solar média também é reduzida (Wang e Duana, 2020). Como a radiação solar é filtrada, a irradiância solar tem como valor aproximado, na Equação 1:

$$I_{sc} = 340 \frac{\text{W}}{\text{m}^2} \quad \text{Eq.1}$$

A energia elétrica gerada pela célula fotovoltaica, depende da irradiância solar, uma grandeza física que indica a densidade de energia solar que incide em uma superfície, por unidade de tempo (W/m^2). A irradiância aumenta gradualmente até atingir um pico próximo às 12:00h, normalmente de 1000 W/m^2 , e depois vai diminuindo com o decorrer do dia. A latitude interfere em seu valor devido à inclinação dos raios solares em determinado local, o que influencia na área em que essa energia vai ser distribuída (Adaramola, 2012). Na linha do Equador, já foram registradas irradiâncias acima de 1200 W/m^2 , o que caracteriza uma overirradiance (Chase *et al.* 2018). Embora essa quantidade de energia seja bastante significativa, isso não significa que a energia solar possa fornecer facilmente toda a nossa energia primária.

Algumas dificuldades com a produção de energia solar incluem dias nublados e a falta de uma maneira razoável de armazenar o "excesso" de energia coletada em dias ensolarados.

Em 2022, conforme o Statistical Review of World Energy (Revisão Estatística de Energia Mundial) (Energyinst, 2023), o mundo produziu 29165,2 TWh (Terawatt-hora) de energia elétrica, 2,3% a mais do que no ano anterior (Energyinst, 2023). A superfície da Terra recebe cerca de 3×10^{24} Joules/ano, ou seja, $9,5 \times 10^4$ TWh de energia solar, cerca de 10.000 vezes a mais do que toda a população terrestre consome.

Quando o foco passa a ser no papel da irradiação na produção de energia, são observados alguns fatores, como por exemplo, além de evitar o sombreamento, o ângulo de inclinação dos painéis deve ser escolhido observando-se alguns critérios referentes aos ângulos azimutal e zenital, como sugere (Villalva, 2012).

Ângulo Azimutal: É o ângulo de orientação com relação ao norte geográfico, tendo o ângulo nulo quando o Sol está na metade de seu trajeto desde o instante em que nasce até se pôr. Para o posicionamento do painel quando se está no hemisfério sul este ângulo é uma referência, uma vez que há um aproveitamento tanto a luz da manhã quanto da tarde, tendo seu ponto de máxima captação ao meio dia solar.

Ângulo Zenital: é o ângulo entre a direção vertical (perpendicular à superfície da Terra) e uma linha reta que liga um observador ao Sol. Quando o Sol está diretamente acima de um local, o ângulo zenital é de 0 graus.

As sugestões de melhor escolha angular para uma planta FV, apresentadas no "Installation and Safety Manual of the Bosch Solar Modules" consistem em escolher um ângulo de inclinação, conforme demonstrado na Tabela 2.

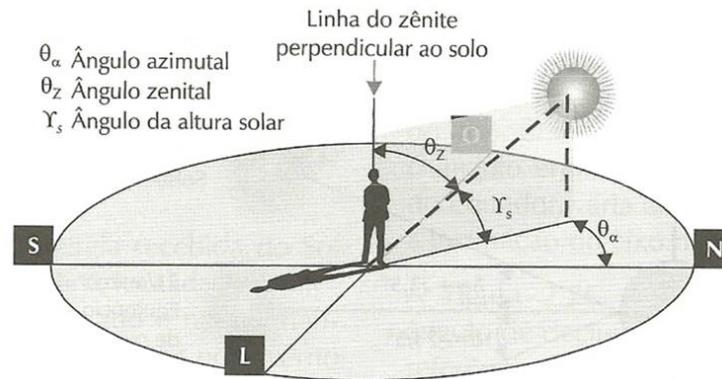
Tabela 2 - Escolha do Ângulo de Inclinação do Módulo.

Latitude Geográfica do Local	Ângulo de inclinação recomendado
0° a 10°	$\alpha = 10^\circ$
10° a 20°	$\alpha = \text{latitude}$
21° a 30°	$\alpha = \text{latitude} + 5^\circ$
31° a 40°	$\alpha = \text{latitude} + 10^\circ$
41° ou mais	$\alpha = \text{latitude} + 15^\circ$

Fonte: Villalva, 2012.

Conforme Blaszczyk (2017), os projetos geralmente usam estruturas de módulos solares de inclinação fixa projetada para fornecer o melhor perfil de produção de energia. De acordo com ANEEL (2018), os módulos FV são geralmente orientados em direção ao equador, com ângulo de inclinação levemente menor que a latitude do local.

Figura 2 - Ilustra as Definições de Ângulos Azimutal, Zenital e Altura Solar



Fonte: Villalva, 2012.

Como exemplificado anteriormente na Figura 2, segundo Duffie e Beckman (1991), para melhor aproveitamento da luz solar, o ideal é que o coletor seja instalado com o ângulo de inclinação igual à latitude local. Com essa configuração, a incidência de raios solares é perpendicular à placa, otimizando a utilização da energia fornecida. Tal fato se deve, que a energia solar anual recebida em função da inclinação da placa é máxima, ou seja, devido a inclinação ser igual ou próxima da latitude local.

A radiação solar é muito importante para a geração solar fotovoltaica. Tanto que é um dos fatores que se leva em consideração no momento de elaboração do dimensionamento do sistema solar fotovoltaico para os clientes.

Porém, os módulos solares fotovoltaicos são fabricados para obter o aproveitamento máximo a uma temperatura de 25°C. Cada grau acima desse nível, o módulo perde um pouco de rendimento. Nesse sentido, apesar da região nordeste apresentar a melhor radiação solar, os sistemas fotovoltaicos da região perdem rendimento devido às altas temperaturas. Já o Rio Grande do Sul apresenta temperaturas médias mais próximas a 25° Celsius, fazendo com que gerar energia solar fotovoltaica no Rio Grande do Sul seja tão vantajoso quanto no nordeste brasileiro. Já a irradiação solar é obtida pela integração da irradiância solar ao longo de um intervalo de tempo. Sua unidade de medida no Sistema Internacional (SI) é expressa em J/m² (Joule por metro quadrado). No entanto, o setor de geração de energia tem adotado usualmente a unidade Wh/m² (Watt-hora por metro quadrado) para expressar a irradiação solar. Esta grandeza é muito utilizada em dimensionamentos de sistemas fotovoltaicos. Segundo Magarreiro *et al.* (2017) para a realização da estimativa de medição é necessário compreender como é composta a irradiância global e seus componentes, ilustradas na Figura 3 e listadas a seguir:

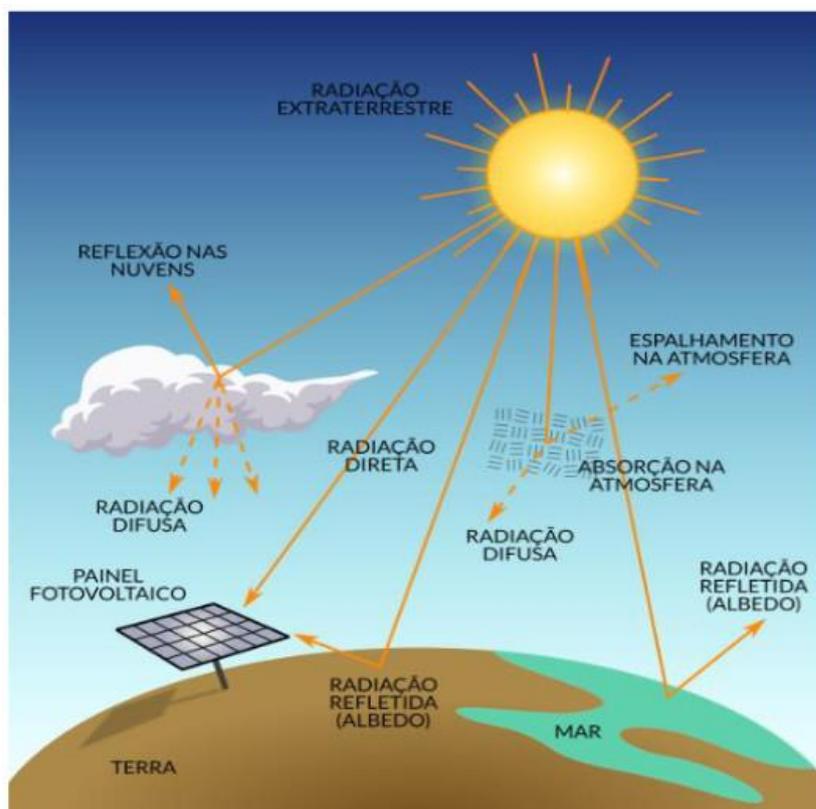
- Irradiância Direta Normal (DNI): Irradiância recebida diretamente do Sol sem sofrer dispersão, sendo medida em uma superfície perpendicular aos raios solares;
- Irradiância Difusa Horizontal (DHI): Irradiância recebida do Sol que sofreu dispersões durante sua trajetória e incidiu sobre a superfície horizontal da placa;
- Irradiância Refletida (RI): Irradiância refletida pela superfície e que incide na placa, a reflexão depende bastante das propriedades ópticas da superfície atingida pelos raios solares. A parcela da irradiância refletida para compor a Irradiância Global Horizontal é insignificante, por isso não é utilizada nas medições (considerada nula);
- Irradiância Global Horizontal (GHI): É a radiação total incidente em uma superfície horizontal por unidade de área. Sendo a soma da Irradiância Direta Normal (DNI), Irradiância Difusa Horizontal (DHI). Equação 2;

As irradiâncias global, direta e difusa guardam entre si a seguinte relação:

$$GHI = DNI * \cos(\theta_z) + DHI \quad \text{Eq. 2}$$

Onde: θ_z é o ângulo zenital.

Figura 3 - Tipos de Radiação Solar.



Fonte: Institutosolar, (2020).

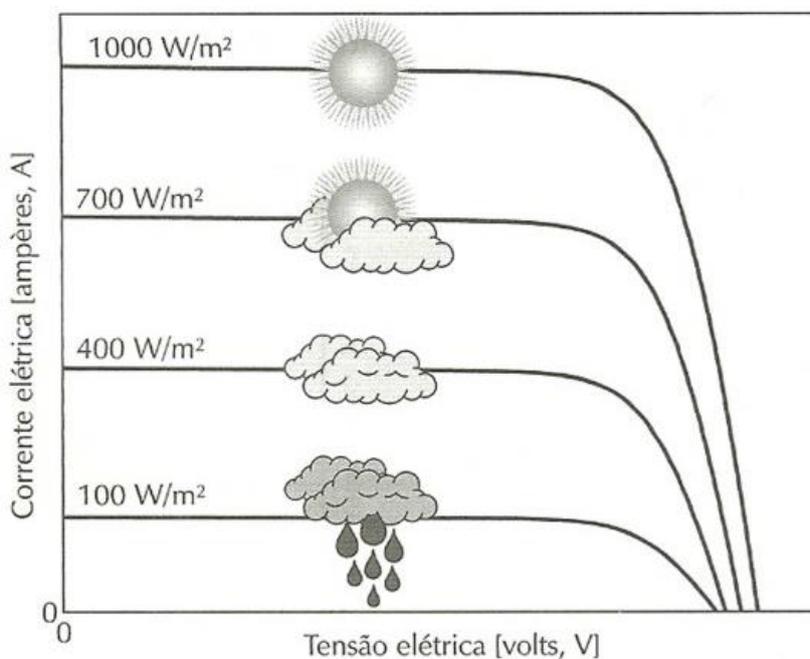
2.1.1 Principais Fatores de Influência na Geração de Energia FV

Segundo Villalva (2012), além das características da carga conectada ao sistema, dois fatores são de fundamental importância na geração de energia a partir das células solares:

- Radiação solar;
- Temperatura do módulo solar.

Ambos os fatores influenciam diretamente na potência fornecida pelo módulo, conforme ilustrado na Figura 4.

Figura 4 - Influência da Radiação Solar na Operação do Módulo Fotovoltaico.

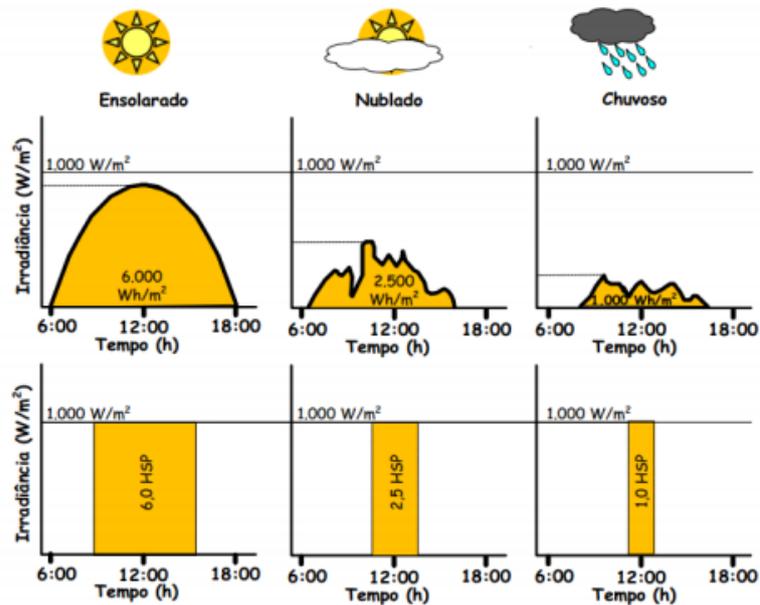


Fonte: Villalva, (2012).

HSP é a abreviação utilizada pelos engenheiros e outros profissionais da área para se referir à hora de Sol pleno ou hora de Sol de pico. Ela representa a insolação diária que determinada superfície (uma casa, um prédio, uma empresa, um estacionamento, entre outros) recebe. A hora de Sol pleno é calculada a partir da divisão da irradiação de determinado local (kWh/m^2) pelo valor padrão de 1000 W/m^2 , conforme visto na Figura 5. O HPS/dia não representa a quantidade de horas de Sol que atingiu o local em um dia, mas sim o equivalente à hora de sol pleno. Digamos que, por exemplo, determinada residência tenha 5200 Wh/m^2 de irradiação em um dia,

isso representa 5,2 horas de sol pleno.

Figura 5 - Comportamento Médio da Irradiância de Acordo com o Clima.



Fonte: E4energiasrenovaveis, (2022).

2.1.2 Índice de Claridade KT

O Índice de Claridade (KT) trata-se de um número sem dimensão que varia de acordo com a quantidade de aerossóis e nuvens presentes na atmosfera em um dado momento, considera a diminuição das componentes difusa ou direta da radiação solar que chega até a superfície terrestre, possibilitando classificar o céu de acordo com a sua nebulosidade, o que foi proposto por Tavares (2005).

Para estimar o valor de H_0 , utiliza-se a Equação 3, proposta por Duffie e Beckman (2013), calculada em função da constante solar ($G_{sc} = 1367 \text{ W/m}^2$), latitude (φ), ângulo solar (δ) ao meio-dia com relação ao plano do Equador, ângulo do pôr do Sol (ω_s) e o dia do ano com base no calendário juliano (N).

$$H_0 = \frac{24}{\pi} \cdot G_{sc} \cdot \left[1 + 0,033 \cdot \cos\left(\frac{360N}{365}\right) \right] \cdot \left(\cos\varphi \cdot \cos\delta \cdot \sin\omega_s + \frac{\pi\omega_s}{180} \cdot \sin\varphi \cdot \sin\delta \right) \quad \text{Eq. 3}$$

Possuindo os valores de H e H_0 tem-se a classificação dos valores de K_t . Assim, é possível aplicá-lo para cada um dos dias abordados no estudo. Para tal, utiliza-se a Equação 4, onde H é a irradiação solar global e H_0 a irradiação solar global extraterrestre, ambas com frequência diária e no plano horizontal.

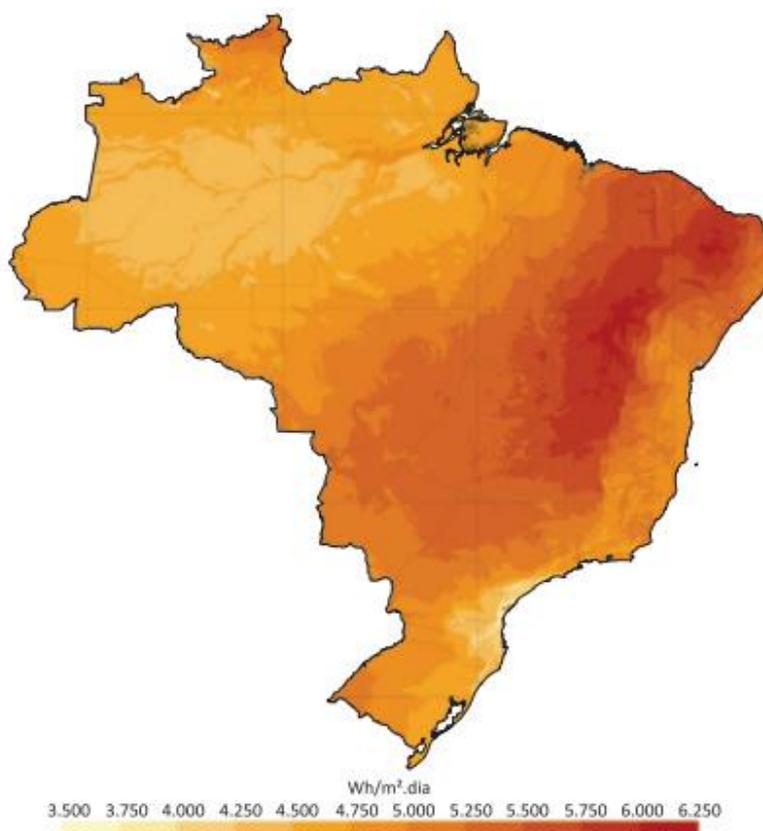
$$K_t = \frac{H}{H_0} \quad \text{Eq.4}$$

Retomando a Eq. 4, a partir dos resultados e dos valores medidos de H, a classificação de cobertura do céu aplicada foi uma modificação proposta por Escobedo *et al.* (2009), onde foram estabelecidos alguns cenários, céu nublado ($0,35 \geq Kt \leq 0,55$) e céu parcialmente claro ($0,55 \geq Kt \leq 0,65$) que foram combinados. Foi utilizado, no referido trabalho, as categorias definidas como: céu nublado ($Kt < 0,35$), céu com cobertura intermediária ($0,35 \geq Kt \leq 0,65$) e céu claro ($Kt > 0,65$). Assim, é proposta uma classificação para todos os anos do estudo e também isolada para cada mês, a fim de identificar a presença de possíveis períodos predominantes.

2.1.3 Radiação Solar no Brasil, Nordeste e nas Plantas Estudadas

A grande extensão territorial e a expressiva área de telhados em unidades residenciais e comerciais, aliadas ao elevado nível de irradiação solar existente no Brasil, representam um enorme potencial para a geração solar centralizada e distribuída.

Figura 6 - Total Diário de Irradiação no Plano Inclinado na Latitude - Média Anual.



Fonte: Pereira *et al.* (2017).

O Atlas Brasileiro de Energia Solar, publicado em 2017 pelo Instituto Nacional de Pesquisas Espaciais – INPE, disponibiliza os valores médios anuais da irradiação

solar no Brasil, Figura 6. De acordo com esse estudo, o Nordeste é a região que possui os melhores parâmetros, apresentando o maior nível de irradiação no plano inclinado (média anual de 6,15 kWh/m²/dia) e menor variabilidade interanual durante o ano (Pereira *et al.*, 2017).

Por essa razão, essa região, em particular sua porção semiárida, onde a elevada irradiação está associada à ocorrência de baixa precipitação e menor cobertura de nuvens ao longo do ano, se credencia a ser o destino prioritário de investimentos em geração de energia elétrica a partir da fonte solar, como já se observa nos leilões públicos.

Uma das plantas fotovoltaicas estudadas está instalada próximo à cidade de Petrolina, em uma área destinada a uma plataforma de pesquisas em energia solar. Banhada pelo Rio São Francisco, a 722 km da cidade de Recife, Estado de Pernambuco, Petrolina apresenta-se como importante polo de desenvolvimento turístico e de exportação de frutas e vinhos, contando com sistemas de transporte aéreo e rodoviário.

Outra vantagem da localização é a proximidade da linha de distribuição em 13,8 kV da Neoenergia (Companhia Energética de Pernambuco), que passa a menos de 100 m de distância do terreno. Latitude: 9° 23' 39" Sul, longitude: 40° 30' 35" Oeste.

A região onde a planta está instalada, encontra-se no sertão do São Francisco Pernambucano e apresenta clima Tropical Semiárido, relevo plano e suave ondulado, com ampla área aberta nas suas redondezas e não há presença de construções nem residências nas proximidades, quanto a vegetação é caracterizada por ser tipicamente caatinga hiperxerófila, além de solo pedregoso com ocorrência mineral de calcário e argila.

Dados meteorológicos históricos que demonstram, em termos de valores médios diários anuais, 7,8 (horas) de insolação diária, resultando em um valor de irradiação média anual em torno de 5,38 kWh/m²/dia (19,38 MJ/m²/dia), temperatura ambiente média anual de cerca de 26,34°C e precipitação pluviométrica em torno de 538,7 milímetros anuais, segundo dados do memorial da CRESA (2020).

Verifica-se que a somatória da irradiação anual global no plano horizontal atinge 1965 kWh/m². Os níveis máximos de irradiação ocorrem entre os meses de setembro a janeiro, com máximo de 6,50 kWh/m²/dia em novembro e mínimos entre maio e julho, ainda assim, com valores satisfatórios, cerca de 4,57 kWh/m²/dia como valor mínimo em junho, demonstrado na Tabela 3.

Tabela 3 - Tabela com Irradiações Médias em Petrolina.

Irradiações Médias Petrolina (kWh/m²/dia)													
Irrad.	Anual	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
GHI	5,76	6,38	6,16	6,02	5,24	4,82	4,57	4,82	5,55	6,32	6,40	6,50	6,38
DHI	2,05	2,22	2,35	2,26	2,10	1,87	1,72	1,76	1,90	1,94	2,07	2,20	2,25
DNI	5,55	6,13	5,34	5,38	4,71	4,82	4,87	5,09	5,73	6,33	5,95	6,13	6,08
LAT	5,78	6,00	5,96	6,03	5,44	5,16	4,97	5,19	5,84	6,40	6,24	6,16	5,95
PAR	2,43	2,63	2,58	2,56	2,38	2,14	2,02	2,08	2,33	2,61	2,68	2,64	2,55

Fonte: Pereira *et al.* (2017).

- GHI: Irradiação global horizontal, do inglês "*Global Horizontal Irradiation*".
- DHI: Irradiação difusa horizontal, do inglês "*Diffuse Horizontal Irradiation*".
- DNI: Irradiação direta normal, do inglês "*Direct Normal Irradiation*".
- LAT: Irradiação global na inclinação da latitude local
- PAR: Irradiação fotossinteticamente ativa, do inglês "*Photosynthetically Active Radiation*".

A outra planta FV está situada em Messias, cidade do Estado do Alagoas. O município se estende por 113,8 km² e contava com 17.856 habitantes no último censo. A densidade demográfica é de 156,9 habitantes por km² no território do município de acordo com IBGE, 2022.

Vizinho dos municípios de Rio Largo, Murici e Flexeiras, Messias situa-se a 12 km ao Norte-Leste de Rio Largo, a cidade mais próxima nos arredores. Messias apresenta uma irradiação média anual de 5,22 kWh/m², entregando uma faixa de 1171 a 1453 kWh/ano por m². Messias (AL) pela proximidade com o litoral tem maiores índices de precipitação 944 mm, conforme visto pelos dados do Cresesb em 2023.

Situado a 104 metros de altitude, Messias tem as seguintes coordenadas geográficas: Latitude: 9° 23' 18" Sul, Longitude: 35° 50' 16" Oeste. O clima é tropical, quente e úmido, com temperatura e pluviosidade média anual histórica de 24°C e 2.200 mm, respectivamente, e uma distinta sazonalidade no regime de precipitação, sendo maio, junho e julho, os meses mais chuvosos e dezembro, janeiro e fevereiro, os mais secos, indicado na Tabela 4 o comportamento da radiação no decorrer do ano de 2023 na região estudada.

Tabela 4 - Tabela com Irradiações Médias em Messias.

Irradiações Médias Messias - Alagoas (kWh/m²/dia)													
Irrad	Anual	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
GHI	5,22	5,87	5,83	5,84	5,06	4,23	3,90	4,00	4,57	5,39	5,67	6,16	6,11
DHI	2,21	2,42	2,43	2,29	2,12	1,97	1,84	1,90	2,09	2,22	2,40	2,38	2,44
DNI	4,51	5,13	4,86	5,17	4,39	3,52	3,30	3,35	3,84	4,57	4,71	5,64	5,58
LAT	5,22	5,53	5,64	5,85	5,25	4,52	4,21	4,30	4,79	5,45	5,53	5,84	5,70
PAR	2,30	2,54	2,52	2,53	2,36	2,08	1,86	1,88	2,04	2,38	2,43	2,51	2,44

Fonte: Pereira *et al.* (2017).

- GHI: Irradiação global horizontal, do inglês "*Global Horizontal Irradiation*".
- DHI: Irradiação difusa horizontal, do inglês "*Diffuse Horizontal Irradiation*".
- DNI: Irradiação direta normal, do inglês "*Direct Normal Irradiation*".
- LAT: Irradiação global na inclinação da latitude local.
- PAR: Irradiação fotossinteticamente ativa, do inglês "*Photosynthetically Active Radiation*".

2.2 Energia Solar Fotovoltaica

A energia solar fotovoltaica é uma fonte de energia renovável e limpa que gera eletricidade a partir da radiação solar. Embora represente uma pequena porcentagem da produção global de energia, alguns países usam quantidades significativas de energia solar, como a China, com 400 GW de potência instalada (Portal Solar, 2024).

Um painel solar, ou módulo solar, é um componente de um sistema fotovoltaico. Eles são construídos a partir de uma série de células fotovoltaicas dispostas em um painel. Eles vêm em uma variedade de formas retangulares e são instalados em combinação para gerar eletricidade (Zhou *et al.*, 2022) Os painéis solares, às vezes também chamados de fotovoltaicos, coletam energia do Sol na forma de luz solar e a convertem em eletricidade que pode ser usada para abastecer residências ou empresas. Esses painéis podem ser usados para complementar a eletricidade de um edifício ou fornecer energia em locais remotos. De forma resumida, a origem da história dos estudos da energia solar deu-se em 1839, após a pesquisa do físico francês Alexandre Edmond Becquerel, que descobriu o efeito fotovoltaico. Em 1883, o cientista americano Charles Fritts criou a primeira célula solar usando selênio coberto com ouro. Este marco da tecnologia fotovoltaica data do ano de 1883, quando foi possível gerar uma corrente contínua e constante para a conversão elétrica máxi -

ma de 1% (enquanto, atualmente, trabalha-se com 20% de eficiência).

Após uma série de acontecimentos – inclusive um prêmio Nobel para Einstein, deu-se início à era moderna da energia solar, em 1954, após a elaboração do processo de dopagem de silício por Calvin Fuller e a criação da célula solar moderna por Russell Shoemaker Ohl, junto ao anúncio da primeira célula fotovoltaica durante uma reunião da National Academy of Sciences, após a descoberta do efeito fotovoltaico e dando início à utilização dos painéis solares em 1958. Fuller foi o químico que desenvolveu, pela primeira vez, o processo de dopagem do silício. Pearson, então, estabilizou as placas de silício a partir de reações químicas produzidas pelo contato de uma junção P-N ou diodo com as placas mergulhadas em lítio, podendo observar um comportamento fotovoltaico nas placas analisadas. A dopagem a laser é frequentemente preferida por apresentar algumas vantagens como: 1) menor custo e maior rapidez; 2) reduzido número de etapas de processo; e 3) possibilidade de implementação nas plantas industriais atuais. No entanto, o dano induzido pelo laser pode reduzir a eficiência da célula solar e, portanto, a influência do processo com radiação laser é um ponto de investigação (Kuo *et al.*, 2018).

Mais adiante, os cientistas do Bell Laboratories foram os pioneiros na fabricação de células de silício que possuíam 6% de conversão, sendo mais eficientes que as anteriores. Uma das primeiras utilizações de painéis solares ocorreu em 1958 no espaço, quando o satélite Vanguard I foi lançado, com o auxílio de um painel de 1 W para alimentar seu rádio na viagem. Além disso, foram construídas as primeiras instalações solares para casas, estabelecimentos e até mesmo para meios de transportes, como ônibus, navio e avião. Para ajudar no resumo do histórico da Energia Solar, na Figura 7 é exemplificada uma linha do tempo abaixo.



Fonte: Opus Solar (S.D.).

Outro fator é o financeiro, por mais que nos últimos anos incentivos fiscais (isenção de taxas) e o aumento do custo com energia elétrica tenham sido fatores que ajudaram a fomentar o mercado de energia solar, ainda não é acessível (e em alguns casos nem rentável) para os consumidores de baixa renda. O tempo de retorno médio varia entre 6 e 10 anos (16% a 10% a.a.), que não é uma taxa ruim já que a atual garantia dos fabricantes, garante um tempo útil de 20 - 25 anos, seguindo as recomendações do manual do fabricante (Canadian Solar, 2017).

Uma desvantagem levantada também é a impossibilidade de gerar energia à noite, logo, o cliente teria que armazenar um banco de baterias para armazenar o excesso de energia gerado durante o dia nos horários de incidência solar e utilizar no período noturno, gerando mais um gasto, uma vez que essas baterias precisam ser substituídas com frequência e precisam ser armazenadas em locais adequados, outra observação é que o uso de baterias não condiz com a ideia de “energia limpa” defendida por muitos incentivadores da energia solar. Vale ressaltar que a eficiência das placas (que já não são altas, entre 15 - 25%) é afetada por exemplo, por posicionamento das placas, sombras, nuvens e sujeiras.

2.2.1 Tipos de Sistemas Fotovoltaicos

2.2.2 Sistemas Conectados à Rede – Grid Tie

Os sistemas fotovoltaicos de conexão à rede, Figura 8, são caracterizados por estarem integrados à rede elétrica que abastece a população. Diferente dos sistemas isolados que atendem a um propósito específico e local, estes sistemas também são capazes de abastecer a rede elétrica com energia que pode ser utilizada por qualquer consumidor da rede. Os sistemas conectados têm uma grande vantagem com relação aos sistemas isolados por não utilizarem baterias e controladores de carga. Isso os torna cerca de 30% mais eficientes e também garante que toda a energia seja utilizada (Alves, 2018), ou localmente ou em outro ponto da rede. Sistemas de conexão à rede podem ser utilizados tanto para abastecer uma residência, ou então simplesmente produzir e injetar a energia na rede elétrica, assim como uma usina hidroelétrica ou térmica.

2.2.3 Sistemas Off-Grid

A energia excedente produzida pelo sistema híbrido tem duas destinações. Quando sai do inversor, ela é direcionada para um carregador que permite que ela seja armazenada em baterias para uso posterior e também lançada na rede. Ao mes-

mo tempo que conta com um banco de baterias para armazenamento, o sistema também é integrado à rede pública de distribuição.

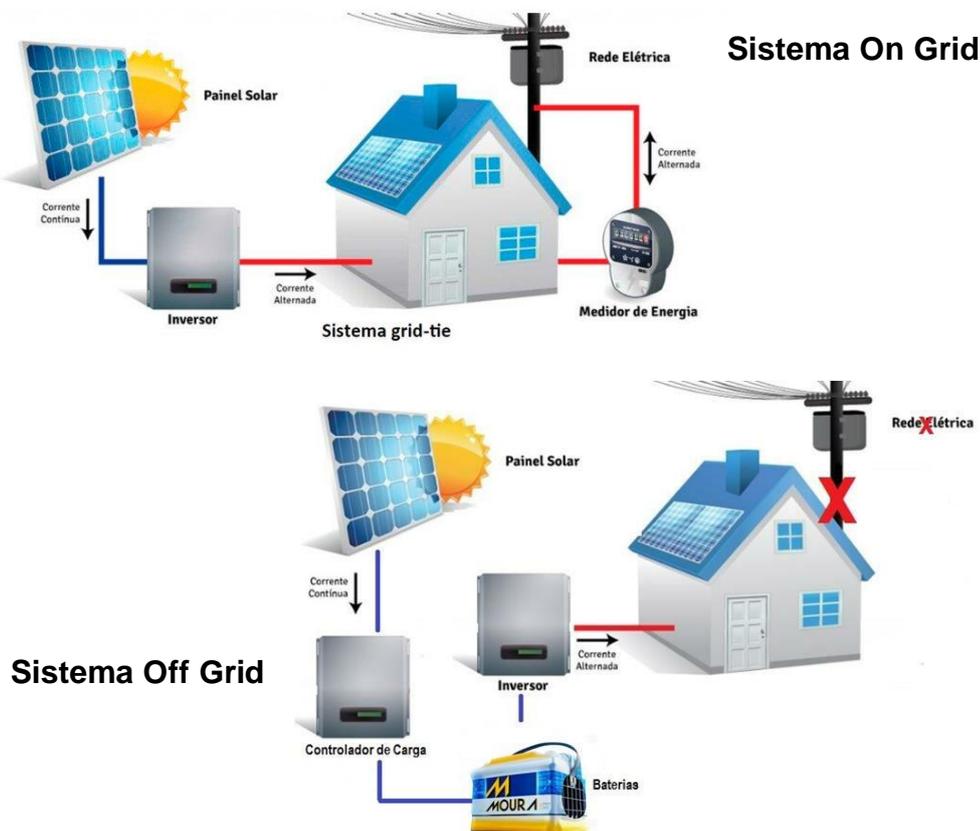
2.2.4 Sistemas Híbridos

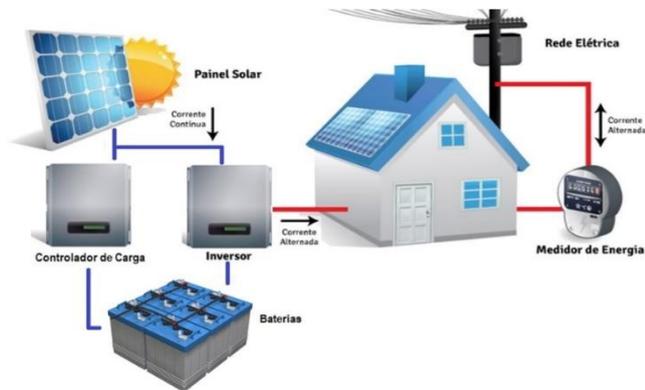
A energia excedente produzida pelo sistema híbrido tem duas destinações. Quando sai do inversor, ela é direcionada para um carregador que permite que ela seja armazenada em baterias para uso posterior e também lançada na rede. Ao mesmo tempo que conta com um banco de baterias para armazenamento, o sistema também é integrado à rede pública de distribuição. Visto na Figura 8.

2.2.5 Usinas Solares

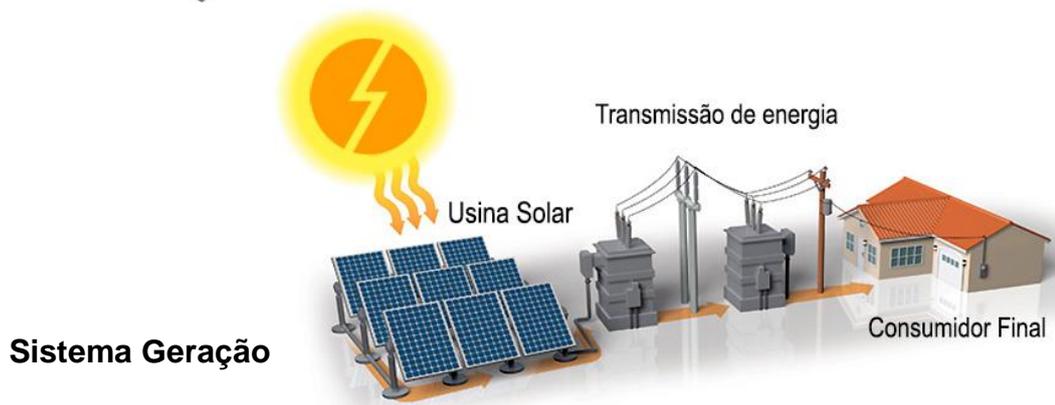
A usina solar, também chamada de parque solar ou complexo solar, é uma grande central geradora elétrica que utiliza milhares de placas fotovoltaicas ou outras tecnologias para, de forma direta ou indireta, transformar a luz do sol em eletricidade. O tamanho da usina varia de centenas de quilowatts a megawatts. Algumas destas instalações estão sobre grandes edifícios, indústria ou no solo próximo a edificações que exigem um consumo intenso de energia. Representado na Figura 8.

Figura 8 - Tipos de Sistemas Fotovoltaicos.





Sistema Híbrido



Sistema Geração

Fonte: Ribsol (2024) Adaptada pelo autor

2.2.6 Componentes de uma Planta Solar

- Painéis solares ou placas solares: São os principais componentes do sistema fotovoltaico de geração de energia. Estes são formados por um conjunto de células fotovoltaicas associadas, eletricamente, em série e/ou paralelo, dependendo das tensões e/ou correntes determinadas em projeto. O conjunto destes módulos é chamado de gerador fotovoltaico e constituem a primeira parte do sistema, ou seja, são os responsáveis no processo de captação da irradiação solar e a sua transformação em energia elétrica;
- Controladores de carga: Também chamado de regulador de carga, este componente é, geralmente, utilizado em sistemas off grid, ou seja, que empregam o uso de baterias para o armazenamento de energia. De acordo com Pereira e Oliveira (2015), os controladores de carga têm como principal função proteger os acumuladores, isto é, as baterias de sobrecargas do sistema. Além disso, se bem regulados, asseguram que o sistema opere em sua máxima eficiência; Inversores:
- Os inversores são dispositivos eletrônicos que fornecem energia elétrica em corrente alternada a partir de uma fonte de energia elétrica em corrente contínua (Pinho e Galdino, 2014).

- Baterias: são dispositivos responsáveis por fazer o armazenamento da energia elétrica gerada pelos módulos, com o intuito de suprir a demanda da mesma na ausência da radiação solar. Com isso, podem ser consideradas de extrema importância, já que a radiação solar não ocorre nos períodos noturnos e é reduzida em dias nublados.

2.3 Célula Fotovoltaica e sua Eficiência

Uma célula fotovoltaica é composta por muitas camadas de materiais, cada uma com uma finalidade específica. A camada mais importante de uma célula fotovoltaica é a camada semicondutora especialmente tratada. Um semicondutor é um elemento ou composto que conduz eletricidade sob algumas condições, mas não em outras. Essa propriedade de não ser um bom isolante nem um bom condutor torna os semicondutores úteis para controlar a corrente elétrica (Li *et al.*, 2017). A condutividade elétrica de um semicondutor depende de uma variedade de condições, incluindo corrente aplicada, intensidade da radiação infravermelha, radiação ultravioleta e luz visível na superfície.

O fato de os semicondutores terem quatro elétrons em sua camada de valência significa que eles formam ligações covalentes perfeitas com quatro átomos vizinhos. Isso cria uma estrutura de rede cristalina. Nesta rede pura, nenhum elétron livre pode conduzir corrente. Por causa disso, um verdadeiro semicondutor é formado quando há impurezas em alguma estrutura cristalina, e são essas impurezas que conferem ao material suas propriedades distintas.

O material mais utilizado nas células fotovoltaicas é o silício (Si), por suas propriedades semicondutoras (Vaishak e Bhale, 2021). Benefícios como quantidade disponível (segundo maior elemento mais abundante na Terra) e baixo custo de fabricação fomentam a escolha do material.

Também estão sendo testados outros materiais alternativos como as células de filmes finos, pois seu processo de fabricação requer menor custo, infelizmente também refletindo na sua baixa eficiência energética quando comparada com as células de silício convencional (Alvarenga, 2004).

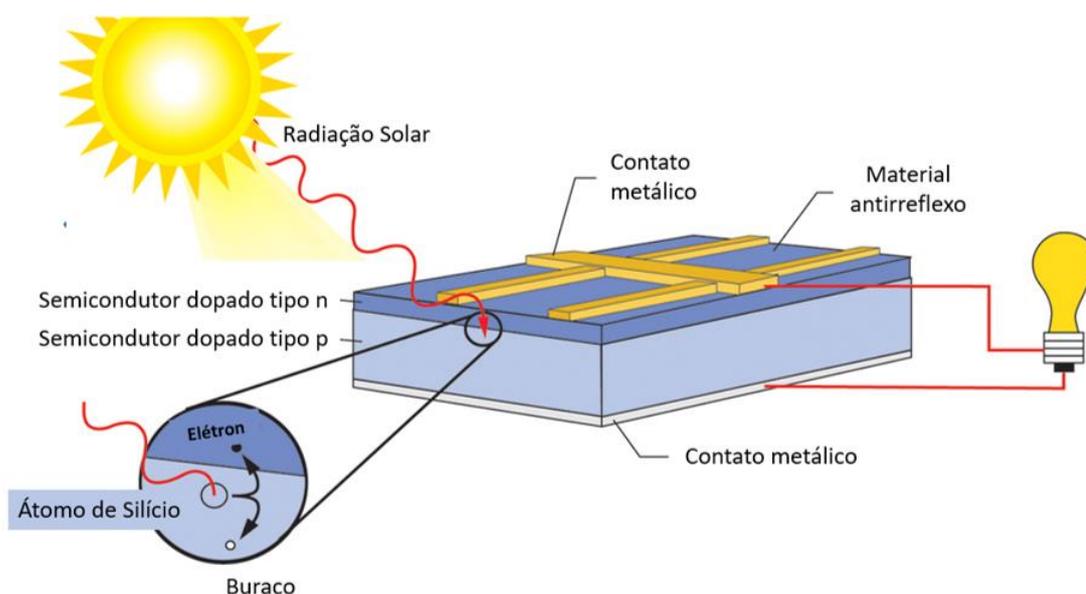
A célula funciona com base no efeito fotovoltaico, ela é construída com material semicondutor (material com características entre um condutor e um meio isolante). O silício tem uma aparência próxima a areia e é o semicondutor utilizado na placa solar utilizada no presente estudo. Apesar de os cristais de silício terem aparência metálica,

não são, de fato, metálicos. Todos os elétrons externos em um cristal de silício estão envolvidos em ligações covalentes perfeitas, de forma que não podem se mover entre os átomos. Um cristal de silício puro é praticamente um isolante, muito pouca eletricidade passa por ele. É possível alterar o comportamento do silício e transformá-lo em um condutor dopando-o. Na dopagem, mistura-se uma pequena quantidade de impurezas a um cristal de silício. Se a dopagem do silício for realizada com o fósforo, o material resultante obtido tem elétrons livres de carga negativa, denominando silício tipo N. Se a dopagem for utilizando o boro, o material obtido tem cargas positivas, obtendo o silício tipo P.

Postos em camadas intercalares, o silício P e N Figura 9, ao ser exposto à luz, alguns elétrons do material da célula ficam mais energéticos devido à absorção de fótons. Com essa energia extra, os elétrons são acelerados, gerando uma corrente através da junção. Esse fluxo de corrente dá origem à diferença de potencial entre as duas faces da junção P-N, esse é o efeito fotovoltaico.

A incidência solar é uma importante influência na produção de energia solar que interfere diretamente no desempenho do sistema fotovoltaico. Esta incidência sofre grande influência da sujeidade, que é sabida ser responsável pela deterioração severa do desempenho de geração fotovoltaica (Heinrich, 2020).

Figura 9 - Esquema do Efeito Fotovoltaico no Átomo de Silício.



Fonte: Oakenergia (2021).

2.3.1 Tipos de Painéis Fotovoltaicos

Figura 10 – Imagens dos tipos de células Fotovoltaicas.



Fonte: Autosolar (S.D.).

Painéis de Células de Silício Monocristalino (mono-Si)

As células de silício monocristalino (mono-Si) Figura 10, contam com uma tecnologia mais antiga se comparada com os outros tipos, porém, sua eficiência na conversão de luz solar em energia elétrica fica entre 14 e 21%, devido à sua boa eficiência, podem converter mais energia ocupando menos espaço se comparado com as células policristalinas ou de filme fino. Isso em virtude à alta complexidade, sofisticação e ao alto custo do processo de fabricação das células de silício monocristalino, que exigem um alto grau de pureza no processamento dos materiais. Além disso, outros desafios atrelados ao processamento e fabricação dessas células são a quantidade de matéria prima requerida e a quantidade de energia consumida no processo de fabricação (Guedes e Torres, 2019).

Painéis de Células de Silício Policristalino (poli-Si)

Células de silício policristalinos (poli-Si), utilizam a mesma matéria prima que as células monocristalinas, a principal diferença é o modo de solidificação dos cristais. No policristalino, a fundição acontece em um bloco, sendo assim, esse método de fundição preserva a formação de múltiplos cristais, quando o cristal é cortado e fatiado, é perceptível essa formação múltipla de cristais. Sua eficiência é ligeiramente menor que a do monocristalino, ficando entre 13 e 17%. Vantajoso pelo custo menor em comparação com o monocristalino, por ter um processo de produção menos rigoroso e um baixo grau de pureza, são células que apresentam eficiência próxima às do silício policristalino, mas exige menor quantidade de energia durante o processo produtivo (Sampaio *et al.*, 2019).

Painéis de Filme Fino

Neste caso, uma fina camada de material é aplicada sobre uma superfície (que pode inclusive, ser irregular ou até flexível). Geralmente a eficiência é menor, porém o custo também é menor e a flexibilidade de aplicação é bastante diferenciada. As células de filme fino são fabricadas a partir de insumos variados, como o telureto de cádmio (CdTe), o seleneto de cobre gálio índio (CIGS) e o silício amorfo (a-Si). Estima-se que essas placas apresentem uma eficiência em torno de 7% a 13%.

2.4 Equipamentos Utilizados na Coleta dos Dados Meteorológicos

As medições de radiação solar ainda são muito escassas dependendo da localidade e da escala temporal de medição conforme observado na base de dados coletadas no INMET. A radiação solar global que chega à superfície da Terra é constituída de duas componentes: a direta e a difusa. A radiação direta é a parcela da radiação solar que chega diretamente (sem sofrer desvio) do disco solar na superfície do solo, e a radiação difusa é a parcela que sofreu espalhamento na atmosfera. Para avaliar com maior exatidão o recurso solar disponível em uma superfície inclinada, como por exemplo um módulo FV, é pertinente dispor de dados medidos com boa precisão dessas duas componentes.

Essas informações podem ser medidas por meio de estações solarimétricas com equipamentos como o piranômetro e o pireliômetro. Entretanto, o alto custo de instalação e manutenção operacional desses equipamentos para cada unidade individual de geração distribuída pode tornar este processo praticamente inviável economicamente (Scolar; Martins; Escobedo, 2003).

Os dados de radiação disponíveis no INMET (Instituto Nacional de Meteorologia) são medidos através dos maquinários tecnológicos instalados nas estações meteorológicas, que são formados por 3 equipamentos de aferição do tempo e da radiação no campo terrestre, o heliógrafo Figura 11, que serve para medir o número de horas em que o Sol brilha diretamente na superfície, o actinógrafo Figura 12, que registra continuamente a energia solar que chega à região e o piranômetro, que acumula a energia solar incidente ao longo do dia, na superfície plana a partir de um ângulo de 180° de visão.

A digitalização de equipamentos e sua teleassistência agrupam as mais diversas estações automáticas no âmbito da formação de uma rede nacional de dados meteorológicos. Conforme visto na Seção 3.1.2 são 750 estações que compõem o sistema do INMET.

Figura 11 - Heliógrafo.



Figura 12 - Actinógrafo.



Fonte: Manual de Engenharia para Sistemas Fotovoltaicos, (2014).

O piranômetro, Figura 13, é um equipamento usado para medir radiação solar em uma superfície plana e é projetado para medir a densidade de fluxo da radiação solar (W/m^2) do hemisfério acima dentro de um intervalo de comprimento de onda de $0,3 \mu m$ a $3 \mu m$.

Figura 13 - Piranômetro



Figura 14 - Pireliômetro



Fonte: Manual de Engenharia para Sistemas Fotovoltaicos, (2014).

Um pireliômetro Figura 14, é um instrumento para a medição da irradiação direta do Sol. A luz solar entra no instrumento através de uma janela e é direcionada para uma termopilha que converte calor em um sinal elétrico que podem ser gravados. Ele utiliza um tubo longo e estreito com uma pequena abertura circular e com um ângulo de captação de cerca de 6° para receber a radiação solar. Como o disco solar subtende um ângulo de aproximadamente $0,5^\circ$, o pireliômetro capta também uma porção da radiação ao redor do Sol, denominada circunsolar.

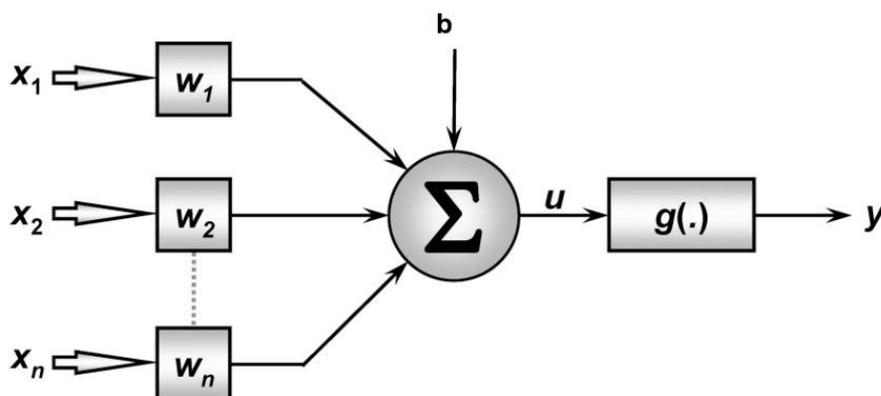
Como o ângulo de abertura do pireliômetro é pequeno, e para fornecer medições, o instrumento é constantemente apontado diretamente para o sol. Por esta razão alguns pireliômetros são montados em um sistema de rastreamento solar, para seguir o movimento aparente do Sol.

2.5 Redes Neurais

Redes Neurais Artificiais (RNAs) são sistemas paralelos e distribuídos constituídos de unidades simples, os nodos ou neurônios, que computam funções matemáticas (especialmente não-lineares). As RNAs apresentam-se como ferramentas estatísticas capazes de armazenar conhecimentos a partir de exemplos, e vêm sendo aplicadas em problemas de ajuste de funções, reconhecimento de padrões, modelos de previsão e outras aplicações em diversas áreas do conhecimento humano, conforme estudos de Haykin (2001).

A principal razão para sua ampla gama de aplicações reside na capacidade de generalização, auto-organização, e processamento temporal que possibilita a resolução de diferentes problemas, das mais diversas complexidades. De maneira análoga ao sistema nervoso de um ser humano, os nodos são dispostos em uma ou mais camadas e interligados por inúmeras conexões, geralmente unidirecionais, denominadas sinapses. A estas conexões associam-se valores, denominados de pesos sinápticos, responsáveis pela ponderação das entradas de cada nodo como forma de armazenamento do conhecimento de um determinado modelo (Haykin, 2001). A estrutura típica de um neurônio artificial é mostrada na Figura 15, onde x_1, x_2, \dots, x_n representam as entradas, w_1, w_2, \dots, w_n são os pesos sinápticos, b representa o bias, g é a função de ativação e y representa a saída.

Figura 15 - Representação de um Neurônio Artificial.



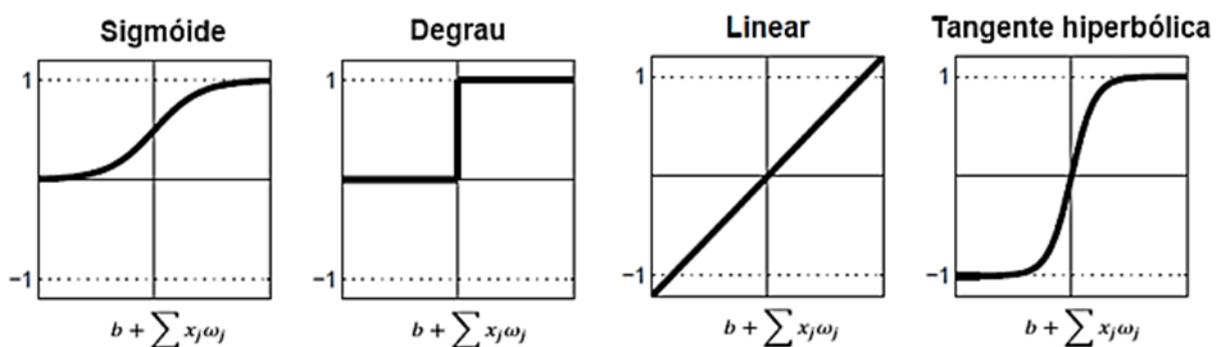
Fonte: Silva; Spatti; Flauzino, (2010) Adaptado pelo autor.

Cada entrada é multiplicada pelo seu respectivo peso sináptico e então entregue ao neurônio via elos de conexão. Em seguida, é realizada a soma dessas entradas com as bias. Posteriormente, esse resultado é introduzido em uma função de ativação g , onde a saída do neurônio é então gerada. O bias causa o aumento ou diminuição da entrada líquida da função de ativação g (Haykin, 1999). Bias em redes neurais é um valor adicional que é adicionado a cada neurônio, juntamente com as entradas, antes de ser aplicada uma função de ativação. Esse valor de bias permite que a rede neural faça ajustes na função de ativação, deslocando-a para cima ou para baixo. Pode-se modelar matematicamente o neurônio da Figura 15, através da Equação 5.

$$y = g \left(b + \sum_{i=1}^n w_i x_i \right) \quad \text{Eq.5}$$

A função de ativação g tem a tarefa de limitar a amplitude da saída do neurônio a um intervalo finito. É ela que tem o poder de atribuir ou não à rede neural a característica de não linearidade, devendo ser escolhida de acordo com a aplicação da rede. Não é necessário que seja a mesma função para todos os neurônios. Algumas das principais funções de ativação são ilustradas na Figura 16.

Figura 16 - Algumas das mais utilizadas funções de ativação em RNAs.



Fonte: Galego *et al.*, (2013) Adaptado pelo autor.

Uma RNA é organizada de forma que os neurônios estejam interconectados e separados por camadas. A disposição dos neurônios nas camadas e o padrão de conexão entre estas definem a arquitetura da RNA. A característica marcante das RNAs é a sua habilidade para aprender a partir de informações do seu ambiente, melhorando

dessa forma o seu desempenho. Uma RNA aprende acerca de seu ambiente através de um processo iterativo de ajustes de seus pesos e níveis de bias. O algoritmo de aprendizagem é um conjunto previamente estabelecido de regras para a solução de um problema de aprendizagem. O treinamento (ajuste dos pesos) pode ser supervisionado (comparando as saídas de referência para cada entrada, de modo a minimizar o erro) ou não supervisionado (quando apenas os dados de entrada são utilizados), os parâmetros são aprendidos durante o treinamento e hiperparâmetros, pelo contrário, não podem ser estimados diretamente do conjunto de treinamento.

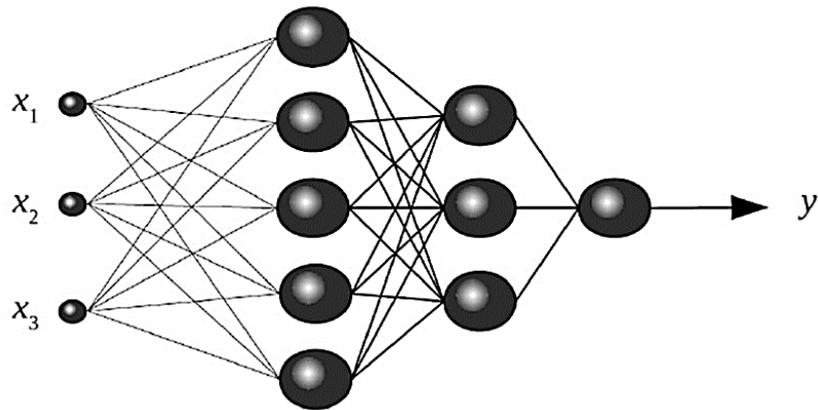
Como exemplificam Wang et al. (2018), em redes neurais, os pesos são os parâmetros ajustados em tempo de treinamento e os hiperparâmetros são, dentre outros, o número de neurônios nas camadas ocultas. A definição dos valores dos hiperparâmetros normalmente é feita por experimentação.

A função ReLU, por exemplo, é uma função de ativação muito popular em deep learning. Ela retorna o valor de entrada se este for positivo e zero se for negativo. A função ReLU é computacionalmente eficiente e tem um bom desempenho em tarefas de classificação e de regressão.

A função tangente hiperbólica, ou tanh, é semelhante à função sigmóide, mas mapeia os valores de entrada para um intervalo entre -1 e 1. É frequentemente usada em redes neurais para modelar relações não lineares em tarefas de classificação e regressão. A função softmax é frequentemente usada em tarefas de classificação multiclasse. Ela transforma um conjunto de valores de entrada em uma distribuição de probabilidade, o que significa que a soma de todas as saídas da função softmax é igual a 1. Isso permite que a rede neural atribua uma probabilidade a cada classe possível.

Além dessas funções, existem muitas outras disponíveis para uso em redes neurais. Algumas dessas funções são menos conhecidas, mas podem ser úteis em situações específicas. Por exemplo, a função ELU é uma variação da função ReLU que tenta mitigar o problema do desvanecimento do gradiente em camadas profundas. Em algumas tarefas de classificação, a função ReLU pode levar a uma precisão mais alta do que a função sigmóide. É importante experimentar diferentes funções de ativação e ajustar outros hiperparâmetros da rede para encontrar a configuração ideal para uma determinada tarefa.

Figura 17 - Exemplo de Rede Neural Artificial do tipo MLP.



Fonte: Gallego *et al.*, (2013).

A mais popular rede neural é a estrutura *Multi Layer Perceptron* (MLP), que consiste em uma camada de entrada, uma ou mais intermediárias e uma de saída (Diagne *et al.*, 2013). Um exemplo de MLP com duas camadas intermediárias (ocultas) é mostrado na Figura 17.

2.6 Estimativas de Produção de Usinas Fotovoltaicas

Tradicionalmente, para dimensionar o tamanho do SFV, é utilizada uma metodologia determinística que leva em consideração, no projeto energético e elétrico, a demanda de energia elétrica e a geração do sistema de energia fotovoltaico. Em geral, o método faz uso de um conjunto de parâmetros de entrada que transformam os resultados de saída os mais próximos do cenário real, necessitando de grandes quantidades e qualidade de dados. Deste modo, nem sempre no dimensionamento os dados estão disponíveis no formato exato para usá-los. Por isso, na maioria das vezes, é necessário utilizar métodos de tratamento de dados que permitam estimar as grandezas das variáveis de interesse (Pinho e Galdino, 2014).

Logo, a abordagem determinística tipicamente modela o cenário do evento observado, dispondo de valores dos parâmetros de entrada, que são conhecidos, e o resultado de saída, que será avaliado. Assim, a saída do modelo mostra ser totalmente determinada pelos valores dos parâmetros e pelos valores iniciais (Melo, Tavares e Villalva, 2021).

Para realizar o dimensionamento adequado dos SFV, é preciso estabelecer um equilíbrio entre a produção e a demanda. Entretanto, para realizar tal operação de forma eficaz, é primordial compreender a característica do comportamento tanto do recurso solar quanto da demanda elétrica requerida (Trigoso, 2004). Por outro lado,

essa relação entre recurso solar e potência elétrica é não-linear e está associada a fatores determinantes para uma efetiva conversão do recurso energético em potência de saída disponível para o sistema (Cabral, 2006).

Desta maneira, para o cálculo de energia incidente, faz-se necessária a utilização de ferramentas computacionais por modelagem numérica, permitindo estimar a grandeza envolvida. Em virtude da complexidade e não solução de forma exata e analítica, exigem-se aproximações do recurso solar para efetuar o cálculo da transposição de dados entre o plano horizontal e o plano inclinado, indicando-se o posicionamento adequado da instalação do SFV. Assim sendo, considera-se esse como sendo o fator definitivo para que o sistema seja viável (Costa, 2015), uma vez que essa variável define a potência do sistema gerador, visto que são grandezas proporcionais (Balfour et al., 2016).

Entre os procedimentos determinísticos, tem-se as simulações computacionais da energia solar fotovoltaica, exigindo-se dados solarimétricos e meteorológicos, respectivamente de radiação solar e temperatura. Na visão de Tavares, Costa, Melo e Villalva (2020), para as simulações otimizadas de energia fotovoltaica, exige-se o uso de dados solarimétricos e climáticos precisos. Melo et al. (2021) apresentam as análises estatísticas com uso de algoritmo de cálculo de posição solar. Já Kitayama, Narvaez, Melo, Costa, Siqueira e Villalva (2018) destacam a análise comparativa entre fontes de dados solarimétricos.

De forma geral, a maioria dos estudos de projetos fotovoltaicos está fundamentada como foi mencionado em modelos determinísticos, ou seja, utilizando-se de simuladores computacionais que determinam os resultados, exatamente, a partir das condições iniciais. Com a abordagem determinística, consideram-se os parâmetros de entrada como valores únicos de operação do sistema, a exemplo de um dia típico que possa permitir representar um valor de saída às condições mais próximas da realidade (Costa, 2015).

Na literatura acadêmica, as diversas pesquisas envolvendo a componente de aleatoriedade nas análises de processos são consideradas atuais e relevantes. De modo geral, as metodologias tradicionais procuram enfatizar os processos pelos métodos determinísticos tais como o uso de equações diferenciais e otimização de funções. No entanto, devido à natureza estocástica intrínseca encontrada em diversas fontes, os estudos recentes têm considerados os diversos processos aleatórios ou

estocásticos (Silva, 2013). Desta maneira, os métodos estocásticos surgem como uma proposta de grande potencial de metodologia alternativa para a determinação de parâmetros com uma abordagem de ferramenta estatística para o dimensionamento de projetos energéticos.

2.7 Softwares de Dimensionamento e Simulação

Para a realização de dimensionamento do projeto fotovoltaico, é preciso levar em consideração diversos fatores, como: perdas ôhmicas, sombreamento do local, inclinação dos módulos fotovoltaicos, posicionamento em relação a trajetória solar, posicionamento geográfico, perdas por temperatura e diversos outros fatores da parte elétrica e intervenções climáticas, as quais são as mais difíceis de serem previstas sem o auxílio de um banco de dados meteorológicos confiável (Oliveira, 2017).

Como existem diversos fatores a serem levados em consideração, o uso de softwares de simulação fotovoltaicos auxilia no dimensionamento do sistema fotovoltaico, pois são capazes de considerar as situações citadas anteriormente.

É importante que os softwares fotovoltaicos possuam boa precisão nos seus resultados, pois é necessário que exista uma ferramenta dessa área que possa realizar uma previsão de geração de energia mais próxima do real produzido pela instalação. Outro fator que influencia no desempenho destes softwares é a qualidade do banco de dados meteorológicos e dos modelos matemáticos utilizados (Rosa, 2014).

Alguns dos softwares usados como ferramentas de dimensionamento de sistemas FV são o PVsyst (PVsyst, 2023) e PV*SOL (PV*SOL, 2021). Entretanto, deve ser feita a observação de que são softwares pagos e como software de rede neural e machine learning será utilizado o Neural Designer. Para os softwares citados, é necessário pagar anuidade ou um custo fixo para cada versão.

2.7.1 Software PV*SOL

O PV*SOL é um software usado por engenheiros, técnicos, arquitetos e instaladores, para planejar e projetar sistemas fotovoltaicos. Projetar sistemas solares personalizados é uma tarefa complicada que exige que os engenheiros levem em conta uma infinidade de fatores, como tamanho e orientação do sistema, número e tempo de uso de aparelhos elétricos, clima geral e radiação solar do sistema, distribuição e capacidade da rede local e muito mais.

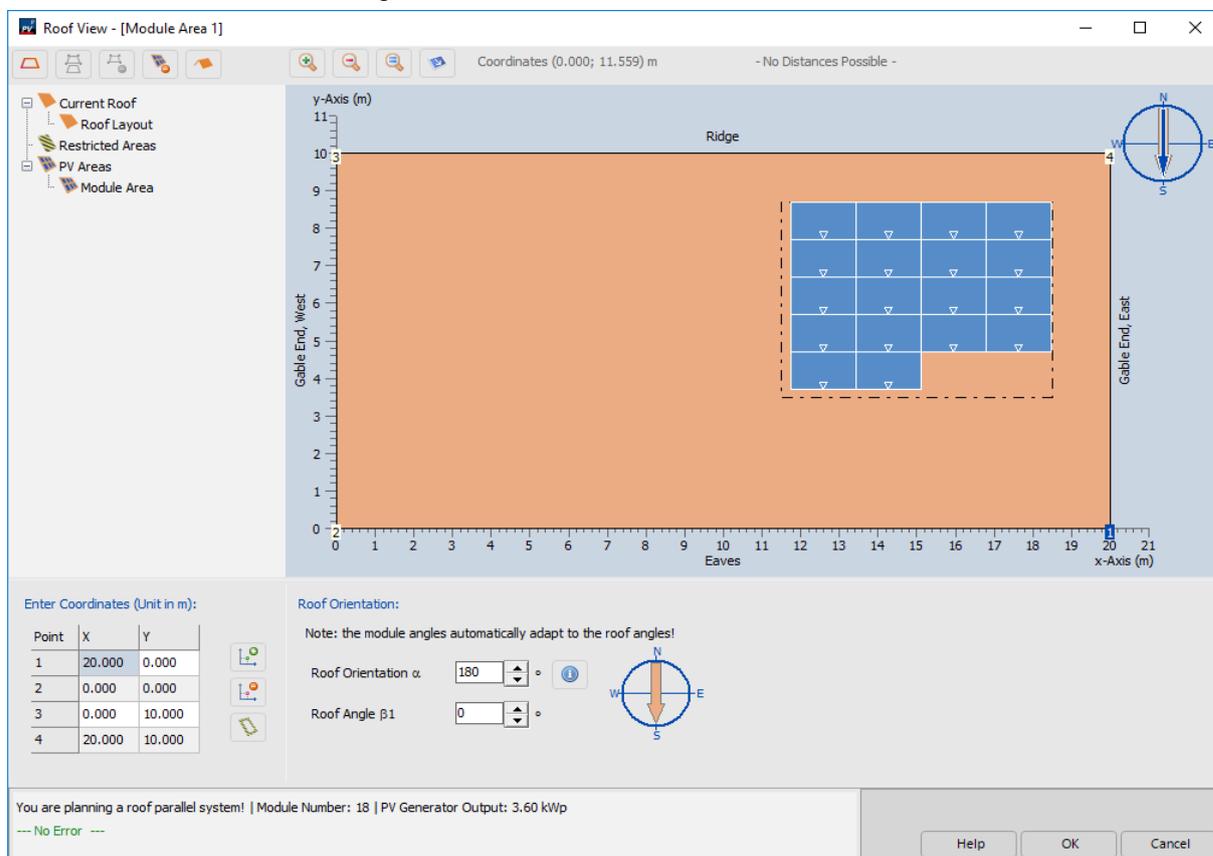
O PV*SOL ajuda a projetar sistemas fotovoltaicos rentáveis eficientes e econômicos. Com uma interface prática e amigável, principalmente com itens como previsões precisas, propostas detalhadas e previsão financeira, na Figura 18 é apresentada uma das telas do PV*SOL.

Como base para testes foi utilizada a versão do PV*SOL Premium 2024 (R3), Valentin Software GmbH – Versão 2024.3.34812.0.

Principais Características:

- Análise de sombreamento 3D;
- Sistemas de armazenamento de bateria;
- Importação de mapas, Banco de dados sempre atualizado e 8000 Dados Climáticos;
- Perfis de carga predefinidos;
- Relatório de projetos configuráveis;
- 17000 Módulos fotovoltaicos cadastrados;
- 4000 modelos de inversores e 900 Sistemas de baterias no banco de dados;

Figura 18 - Amostra de uma das telas do PV*SOL.

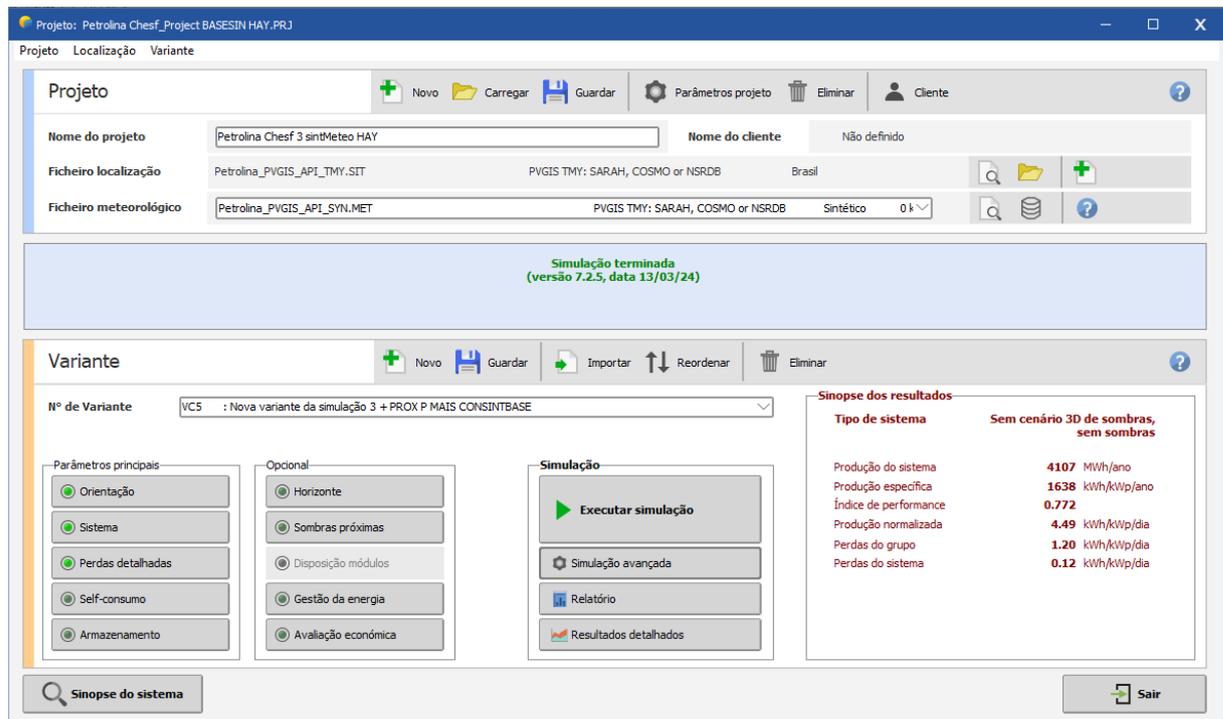


Fonte: PV*SOL, (2024).

2.7.2 Software PVsyst

O PVsyst foi projetado para ser usado por arquitetos, engenheiros, técnicos e pesquisadores. O PVsyst é capaz de importar dados meteorológicos, bem como dados técnicos de muitas fontes diferentes.

Figura 19 - Amostra de uma das telas do PVsyst.



Fonte: PVsyst, (2024).

Principais Características:

- Permite que os usuários insiram dados específicos sobre seus sistemas solares. Ex. dados sobre os módulos solares fotovoltaicos e inversores;
- O PVsyst pode simular o desempenho de um sistema de energia sob várias condições. Ex. A orientação dos painéis solares, a localização e o clima do local, os padrões de carga e consumo elétrico;
- Oferece uma gama de opções avançadas de personalização para o design do sistema fotovoltaico. Isso inclui a modelagem de diferentes tecnologias de painel, incorporando sombreamento e outros fatores específicos do local e otimizando o desempenho do sistema com base em vários critérios;
- Precisão: O PVsyst usa algoritmos avançados e bancos de dados para simular o desempenho dos sistemas de energia solar.
- Flexibilidade: O PVsyst permite aos usuários inserir uma ampla gama de dados e personalizar suas simulações para suas necessidades.

- Facilidade de uso: PVsyst torna mais fácil para os profissionais que trabalham energia solar inserir dados, executar simulações e analisar resultados, pelo que pode ser visto na Figura 19.

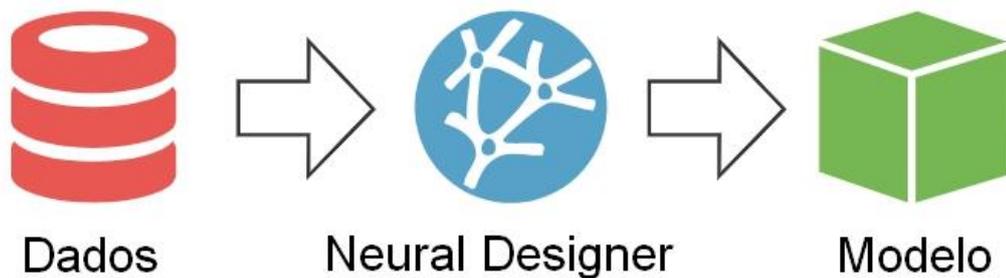
Versão utilizada nos estudos: PVsyst 7.2.5 (rev 22518), Group of Energy Institute of the Sciences of the Environment University of Geneva, Swiss federal institution.

2.7.3 Neural Designer

O Neural Designer é um aplicativo multimodal de uso para ciência de dados e machine learning.

Ele permite a construção de modelos de redes neurais sem codificação ou construção de diagramas de blocos. Neural Designer é uma plataforma de ciência de dados e aprendizado de máquina capaz de simular e otimizar os processos da sua organização, pesquisa e estudos utilizando os dados disponíveis.

Figura 20 - Modelo Utilizado pelo Neural Designer.



Fonte: Neural Designer, (2024).

O Neural Designer, também tem como utilidade a descoberta de relacionamentos, reconhecimento de padrões e previsão de tendências a partir dos seus dados, parte do seu processo é mostrado nas Figuras 20 e 21.

Figura 21 - Funcionalidades Neural Designer.



Fonte: Neural Designer, (2024).

Casos de uso do Neural Designer:

- Bancário
- Energia
- Indústria
- Meio Ambiente
- Assistência Médica
- Varejo

Neural Designer usa técnicas de computação de alto desempenho, como otimização de uso de memória, paralelização de CPU e aceleração de GPU. Conseqüentemente, podendo analisar conjuntos de dados maiores em menos tempo.

Versão do Neural Designer utilizada nos estudos foi a Neural Designer - Editor Version 608, com arquitetura para computadores de 64 bits (X64), com licença para estudos fornecida pelo fabricante.

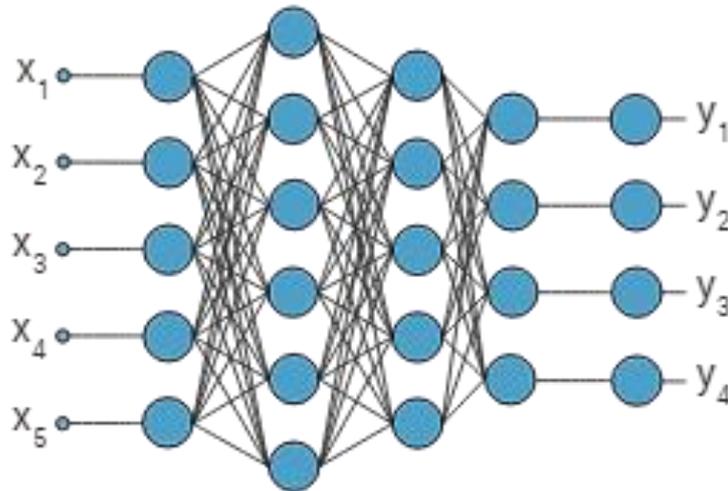
Figura 22 - Ciclo Neural Designer.



Fonte: Neural Designer, (2023) Adaptado pelo autor.

É especializada em redes neurais, que é a técnica mais potente para aprendizado de máquina, com exemplo de rede neural, na Figura 23 abaixo.

Figura 23 - Exemplo de Rede Neural.



Fonte: Neural Designer, (2024).

2.7.3.1 Fonte de Dados

As variantes utilizadas são armazenadas em um arquivo de dados. O formato mais utilizado para um conjunto de dados é um arquivo CSV. Como referência, o ideal é a exportação do arquivo de planilha, consulta SQL e para o formato CSV ou TXT.

2.7.3.2 Variáveis

As variáveis são as colunas da tabela de dados. As variáveis podem representar medidas físicas (temperatura, velocidade...), características pessoais (sexo, idade...), dimensões de marketing (tempo recente, frequência, monetária).

Quanto ao seu uso, podemos falar sobre:

- Variáveis de Entrada: Variáveis de entrada são as variáveis independentes no modelo. Eles também são chamados de recursos ou atributos. As variáveis de entrada podem ser contínuas, binárias ou categóricas;
- Variáveis de Destino: Variáveis alvo são as variáveis dependentes no modelo;
- Em problemas de regressão, os alvos são variáveis contínuas (consumo de energia, qualidade do produto...). Por outro lado, em problemas de classificação, os alvos são binários (falha, rotatividade...) ou categóricos (o tipo de objeto, atividade...);
- Neste tipo de aplicação, os alvos também são chamados de categorias ou rótulos;
- Variáveis não utilizadas: Variáveis não utilizadas não são entradas nem alvos. Podemos definir uma variável como “*Unused*” quando ela não fornece nenhuma informação ao modelo (número de identificação, endereço);
- Variáveis constantes são aquelas colunas na matriz de dados que sempre têm o mesmo valor. Devem ser definidos como não utilizados, pois não fornecem nenhuma informação ao modelo, mas aumentam sua complexidade.

2.7.3.3 Amostras

Amostras são as linhas da tabela de dados. Eles também são chamados de instâncias ou pontos. Projetar uma rede neural para memorizar um conjunto de dados não ajuda. Em vez disso, opta-se que a rede neural funcione com precisão em novos dados e generalize.

Para conseguir isso, dividimos o conjunto de dados em diferentes subconjuntos:

- Amostras de Treinamento: Durante o design do modelo, geralmente precisamos tentar configurações diferentes. Por exemplo, podemos construir vários modelos com arquiteturas diferentes e comparar seu desempenho. Para construir todos esses modelos, utilizamos as amostras de treinamento;
- Amostras de seleção: Amostras de seleção são utilizadas para escolher a rede neural com as melhores propriedades de generalização. Desta forma, construímos diferen-

tes modelos com o subconjunto de treinamento e selecionamos aquele que funciona melhor no subconjunto selecionado;

- Amostras de Teste: Amostras de teste são usadas para validar o funcionamento do modelo. Treinamos diferentes modelos com as amostras de treinamento, selecionamos aquele que apresenta melhor desempenho nas amostras selecionadas e são testadas suas capacidades com amostras de teste;
- Amostras não utilizadas: Algumas amostras podem distorcer o modelo em vez de fornecer informações úteis ao modelo. Por exemplo, valores discrepantes nos dados podem fazer com que a rede neural funcione de forma ineficiente. Para corrigir esses problemas, podemos definir essas amostras como não utilizadas. O padrão é usar 60% das amostras para treinamento, 20% para seleção e 20% para teste. A divisão das amostras pode ser realizada em ordem sequencial ou aleatoriamente. Também podemos definir amostras repetidas como não utilizadas, pois elas fornecem informações redundantes ao modelo.

2.7.3.4 Valores Ausentes

Um conjunto de dados também pode conter valores ausentes e elementos ausentes. Normalmente, os valores ausentes são indicados por um rótulo no conjunto de dados. Alguns rótulos padrão para valores ausentes são NA (não disponível), NaN (não é um número), desconhecido ou ?. Não é recomendado valores numéricos aqui, como -999, pois podem ser confundidos com um valor real.

Existem duas maneiras de lidar com valores ausentes:

- Valores ausentes sem uso: Se o número de amostras no conjunto de dados for significativo e o número de valores faltantes for pequeno, podemos excluir da análise as amostras com valores faltantes. Dessa forma, o método *“unusing”* define essas amostras com valores ausentes como *“Unuse”*;
- Imputação de valores ausentes: Se o conjunto de dados for pequeno ou o número de valores omissos for significativo, não poderá se dar ao luxo de cancelar a utilização das amostras com valores omissos. Nestes casos, é aconselhável atribuir valores prováveis aos dados faltantes. O método de imputação mais comum é substituir os valores faltantes pelo valor médio da variável correspondente. Embora, no presente trabalho optou-se pelo modelo de Angström-Prescott para preenchimento de dados faltantes e discrepantes, (PEREIRA et al., 2002) que será detalhado mais adiante.

2.7.3.5 Definições Gerais do Software Neural Designer

O software Neural Designer possui as seguintes etapas:

- **Arquivo de Dados:** são importados os dados clicando no botão 'Procurar arquivo de dados'. Isso permitirá que você acesse e seja carregado o arquivo de dados no aplicativo. Os tipos de dados suportados incluem CSV, Excel e OpenOffice Calc; Depois da importação dos dados, é visualizado em seguida o número de colunas e linhas em seu conjunto de dados. O número de colunas representa o número de recursos ou variáveis em seu conjunto de dados, enquanto o número de linhas representa o número de amostras ou instâncias, exemplificadas no estudo na Tabela 6. Para garantir que a rede seja treinada e avaliada corretamente, é importante que seu conjunto de dados tenha o número correto de linhas e colunas e esteja no formato correto para os dados e arquitetura de rede específicos;
- **Rede Neural:** É um modelo computacional de inspiração biológica composto por neurônios artificiais organizados em arquitetura de rede. Essas redes possuem parâmetros ajustáveis, permitindo-lhes realizar tarefas específicas. As redes neurais podem aproximar qualquer função com um grau de precisão desejado, tornando-as versáteis para diversas aplicações. Os tipos de camadas comuns para aproximação, classificação e previsão incluem camadas perceptron, probabilísticas, LSTM, escalonamento, uniscaling e delimitadoras. Para aplicações especializadas, como visão computacional ou reconhecimento de fala, outros tipos de camadas, como camadas convolucionais ou associativas, são frequentemente usados.
- **Estratégias de Treinamento:** Uma estratégia de treinamento define a abordagem usada para otimizar os parâmetros da rede neural e minimizar o erro entre as previsões da rede e os valores alvo reais. A escolha da estratégia de treinamento pode impactar significativamente o desempenho e a capacidade de generalização do modelo.
- Normalmente, as estratégias de treinamento envolvem algoritmos de otimização iterativos, como gradiente descendente ou suas variantes, que ajustam os pesos e vieses da rede para minimizar uma função de perda, como erro quadrático médio, entropia cruzada ou outros. Para evitar o overfitting (modelo ajustado aos dados de treino e aos novos dados) e alcançar o melhor desempenho possível, as estratégi-

as de treinamento também podem incluir técnicas de regularização, cronogramas de taxas de aprendizagem ou critérios de parada antecipada.

- **Seleção de Modelo:** A seleção do modelo é o processo de escolha da melhor arquitetura de rede neural, estratégia de treinamento e 2 hiperparâmetros que resultam no maior desempenho e capacidade de generalização para um determinado conjunto de dados. Envolveu no caso estudado avaliar diferentes combinações de arquiteturas de rede, funções de ativação, tamanhos de camada, estratégias de treinamento e outros hiperparâmetros para encontrar o modelo mais adequado para a tarefa. As técnicas de seleção de modelos podem incluir tentativa e erro, pesquisa em grade, pesquisa aleatória ou métodos mais avançados, como otimização bayesiana. O objetivo foi encontrar um equilíbrio entre a complexidade do modelo e a sua capacidade de generalização para novos dados, evitando sobreajuste ou subajuste.

Tabela 5 - Quadro de Perceptrons

Camada Perceptron	Número de Entradas	Número de Neurônios	Função de Ativação
1	6	3	Tangente Hiperbólica
2	3	1	Linear

Fonte: Neural Designer, (2024) Adaptado pelo autor.

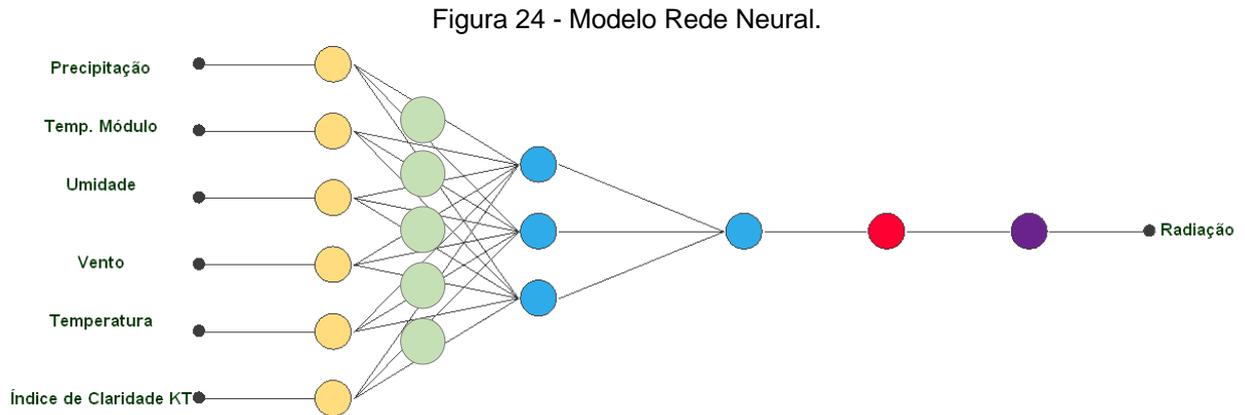
Tabela 6 - Quadro de Amostras.

	Petrolina	Messias	% Amostras
Amostras de Treinamento	2697	2441	60%
Amostras de Seleção	899	813	20%
Amostras de Teste	899	813	20%
Amostras não utilizadas	0	0	0%

Fonte: Neural Designer, (2024) Adaptado pelo autor.

Para estipular o número de camadas ocultas foram utilizadas duas linhas de pensamento, a de inserir dois terços do total de neurônios da camada de entrada somado com o número de neurônios da camada de saída, ou seja, em uma camada de entrada com 6 neurônios e a de saída com 1 neurônio são adicionados 5 neurônios na camada oculta ($6 * \frac{2}{3} + 1 = 5$). E alguns autores também citam que o número de neurônios da camada oculta deve ser menor que o dobro do tamanho da camada de entrada, ou seja, em uma rede neural com 6 neurônios de entrada, a camada oculta

deve conter menos que 12 neurônios, Teorema Kolmogorov (Silva, 2005). Figura 24.



Fonte: Neural Designer, (2024) Adaptado pelo autor.

A Figura 24, mostra uma representação gráfica da arquitetura da rede. Ele contém as seguintes camadas, algumas especificadas na Tabela 5:

- Camada de escala com 6 neurônios (amarelo);
- Camada oculta calculada com 5 neurônios (verde);
- Camada Perceptron com 3 neurônios (azul);
- Camada Perceptron com 1 neurônio (azul);
- Camada de descalonamento com 1 neurônio (vermelho);
- Camada delimitadora com 1 neurônio (roxo).

A função ReLU foi testada nos estudos, por ser uma função muito popular em deep learning. Ela retorna o valor de entrada se este for positivo e zero se for negativo. Foi eficiente computacionalmente e com um bom desempenho em tarefas de classificação e de regressão das variáveis testadas.

A função tangente hiperbólica, ou tanh, é semelhante à função sigmóide, mas mapeia os valores de entrada para um intervalo entre -1 e 1. Foi a função de ativação prioritária usada nesse sistema de redes neurais para modelar relações não lineares em tarefas de classificação e regressão, conforme (Braga, 2007).

Além dessas funções, existem muitas outras disponíveis para uso em redes neurais. Por exemplo, a função ELU é uma variação da função ReLU que tenta mitigar o problema do desvanecimento do gradiente em camadas profundas.

Em algumas tarefas de classificação, a função ReLU pode levar a uma precisão mais alta do que a função sigmóide, embora isso não foi constatado nos testes.

O método de regularização L2 escolhido (A regularização L2 reduziu a variância do modelo, tornando-o mais estável e menos sensível a pequenas variações nos dados de treinamento), consiste na soma quadrada de todos os parâmetros na rede neural. O termo de regularização é ponderado por um parâmetro. Se a solução for muito suave, precisamos diminuir o peso. Por outro lado, precisamos aumentar o peso se a solução oscilar muito. No caso, o peso escolhido foi diminuído para manter a suavização dos dados, ficando em 0,01.

O problema de aprendizado para redes neurais consiste em buscar um conjunto de parâmetros nos quais o índice de perda assume um valor mínimo. A condição necessária afirma que o gradiente é zero quando a rede neural está em um mínimo do índice de perda. O índice de perda observado é geralmente uma função não linear dos parâmetros. Consequentemente, encontrar algoritmos de otimização fechados para os mínimos é impossível. Em vez disso, foi considerada uma busca pelo espaço de parâmetros consistindo em uma sucessão de etapas ou épocas. A perda diminui em cada época ajustando os parâmetros da rede neural. A mudança de parâmetros entre duas épocas é chamada de incremento de parâmetros. O treinamento de uma rede neural envolveu a utilização repetida de um conjunto de dados de treinamento para ajustar os pesos sinápticos entre os neurônios. Cada apresentação completa de todo o conjunto de dados é chamada de época, foi utilizada a marca de 1000 épocas de teste, valores acima disso apresentam custo computacional alto e demora no processamento.

O Método quase-Newton (QNM), como método de otimização do algoritmo usa o Hessiano da função de perda, uma matriz de segundas derivadas, para calcular a direção de aprendizagem. Como ele utiliza informações de alta ordem, a direção de aprendizagem aponta para o mínimo da função de perda com maior precisão. A desvantagem é que calcular a matriz Hessiana é muito caro computacionalmente. O método Quasi-Newton é baseado no método de Newton, mas não requer o cálculo de segundas derivadas. Em vez disso, calcula uma aproximação do Hessiano inverso em cada iteração do algoritmo usando apenas informações de gradiente. Outro ponto relevante é o número máximo de iterações em que o erro de seleção aumenta, que foi definido em 100 iterações. Critério de parada de treinamento 0,001 e foi optado outros critérios de parada: A melhoria de perdas em uma época é menor que um valor

definido, a perda foi minimizada para um valor objetivo, número máximo de épocas é atingido, tempo máximo de computação foi excedido e o erro no subconjunto selecionado aumenta várias épocas.

Um exemplo de um dos produtos do Software Neural Designer está no anexo no fim do documento, onde está a codificação em Python que resulta em valores de produção energética de acordo com as entradas inseridas.

2.8 Estudos Similares

Um estudo dirigido por Barros (2022), apresentou uma pesquisa utilizando o PV*SOL e PVSyst para a cidade de Colônia Leopoldina (AL), cujo objetivo da pesquisa foi demonstrar como utilizar os softwares. A comparação entre o PVSyst e o PV*SOL foi elaborada com base em uma unidade de geração FV. Entre os vários modelos existentes atualmente, inclusive os dois softwares estudados, há diferenças que podem favorecer inúmeros tipos de instalações, logo, cada uma das ferramentas de simulação e dimensionamento FV se destaca em uma área de atuação como, e ressalta nos seus estudos as peculiaridades de cada um e as contribuições de e motivações da escolha dos mesmos.

Medeiros (2023) conduziu um estudo, analisando modelo utilizados para estimar a geração de energia de uma usina fotovoltaica localizada no semiárido brasileiro, e, especificamente, a planta fotovoltaica tinha como local Petrolina. Diversos grupos de modelos foram utilizados para estimar a produção anual da UFV, sendo a acurácia dos mesmos fortemente dependente das condições climáticas e das características do sistema segundo o autor. Foram analisados detalhadamente os modelos de separação da irradiância global horizontal (GHI) nas componentes direta e difusa, bem como os modelos de transposição e os modelos do comportamento térmico e elétrico dos módulos.

Em relação aos estudos sobre o Neural Designer, Ranganathan *et al.* (2021) e a Constantin e López (2023), destacam o uso da planta de geração de energia solar instalada em Berkeley, CA. E peculiaridades do software Neural Designer para uso geral, assim como uso mais específico em predição e projetos de energias renováveis.

Pelos estudos de Rocha (2019), cujo objetivo foi examinar e comparar a produção de energia simulada pelo software PVSyst com a produção solar real de um sistema fotovoltaico na cidade de Rio Negro, no estado do Paraná. Para isso, a metodologia incluiu uma visita ao local do sistema fotovoltaico, onde foram tiradas fo-

tografias que mostraram a condição original antes da instalação e a situação após a implementação do sistema. Utilizando dados de irradiação global horizontal e difusa extraídos do Atlas de Energia Solar do Estado do Paraná, assim como os parâmetros de inclinação e desvio azimutal, onde foi possível realizar a simulação da geração de energia do sistema, gerando valores precisos. Essa informação possibilitou a criação de gráficos que compararam a energia realmente produzida com a energia simulada, permitindo uma análise mais clara das discrepâncias mensais ao longo de todo o ano considerado.

Para Ströher (2020), seu estudo teve como foco analisar a confiabilidade da simulação computacional no contexto de projetos de energia solar fotovoltaica, especificamente usando o software PV*Sol. A presença de software de simulação é comumente vista em diversas fases do projeto, mas há uma falta de análise sobre conformidade de desempenho. Fatores como orientação adequada para luz solar e inclinação do módulo devem ser considerados para geração de energia otimizada. Este estudo comparativo focou em resultados obtidos de uma ferramenta de simulação computacional em um ambiente de instalação real.

De acordo com Dos Santos e De Lima (2022), com seu trabalho que apresentou um estudo de caso detalhado sobre a contribuição do software PVsyst para a elaboração de um projeto de sistema fotovoltaico em Uberlândia-MG. Apresentando todas as principais funcionalidades do software e dimensionamento, avaliando a irradiância solar em função do tempo, eficiência dos módulos fotovoltaicos e a associação dos módulos propostos em função do acoplamento com o inversor.

Também foi analisado o estudo elaborado por Machado (2020), onde o mesmo apresenta o resultado de simulações da planta FV de uma das instalações FV que está situada no campus da Unicamp e que possui potência instalada de 22,95 kWp. A simulação foi realizada em diferentes softwares visando obter dados para análises futuras e verificar se a instalação FV funciona como projetado. Para isso, foram utilizados os softwares HelioScope, PV*SOL e PVsyst para as simulações, e em seguida comparados os resultados com os meses contendo os valores de geração real da planta FV e que obteve desempenho satisfatório em relação aos valores de monitoramento da planta real.

Umar et al. (2018), em seu artigo são apresentados 10 softwares de simulação com suas principais funcionalidades e desenvolvedores dessas ferramentas. Os prin-

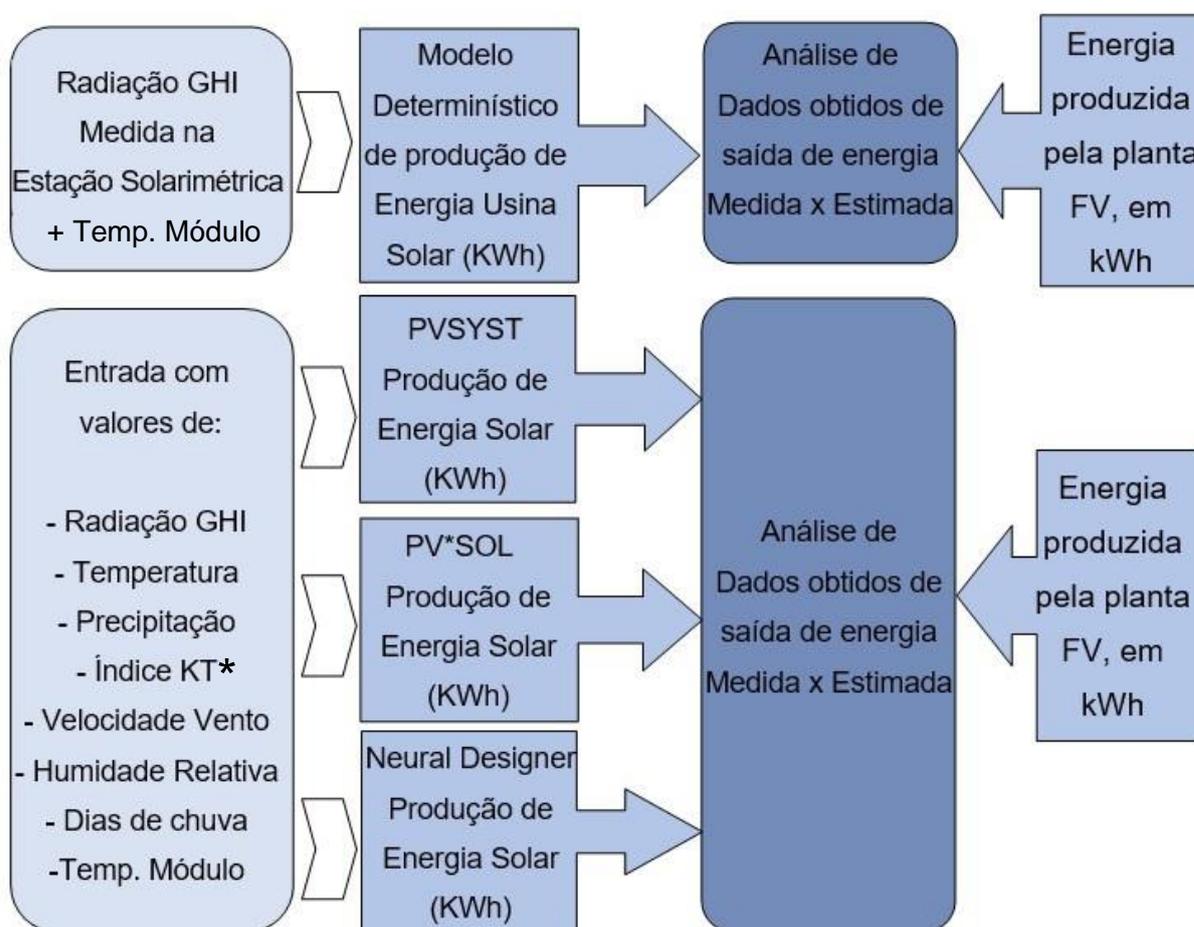
Os principais objetivos são destacar pesquisas para identificar o software adequado para análise de pesquisa e realizar análises de degradação e desempenho de usina FV. Um estudo de caso sobre a análise de desempenho de uma usina de energia solar fotovoltaica conectada à rede de 1 MW, foi realizado usando essas ferramentas de simulação. Os resultados da simulação são então comparados com os dados reais de potência da planta para identificar os softwares adequados e mais eficazes para pesquisa e desenvolvimento. Este estudo é útil para futuros estudos sobre degradação e análise de desempenho de usinas FV e uma comparação de várias simulações de usinas fotovoltaicas e ferramentas para identificar o software mais adequado.

Conforme Ramos et al. (2022), apresentou uma avaliação utilizando o PVsyst do desempenho da planta fotovoltaica conectada à rede, com potência instalada de 2,5MWp. Esta planta, que pertence à Companhia Hidro Elétrica do São Francisco (Chesf) e está localizada no Centro de Referência em Energia Solar de Petrolina (CRESP), contando com um sistema de supervisão e coleta de dados (Supervisory Control and Data Acquisition - SCADA), além de uma estação solarimétrica, cujos dados foram empregados neste estudo.

3 MATERIAIS E MÉTODOS

Nesta seção serão apresentados os materiais e métodos de pesquisa utilizada ao longo deste trabalho, o desenvolvimento dos instrumentos de coleta de dados, a coleta de dados em si, além do tratamento e análise destes dados. Tem como premissa detalhar todos os procedimentos e insumos utilizados, abaixo na Figura 25, por exemplo, está o esboço das entradas e saídas utilizadas no projeto e seu fluxo na obtenção dos resultados esperados no estudo. O nível de detalhamento e interações entre as partes de cada etapa será descrito no decorrer da seção.

Figura 25 - Modelo de entradas e saídas do projeto



Fonte: Elaborada pelo autor

Onde:

A primeira coluna representa: As entradas de dados coletados, filtrados e tratados das estações meteorológicas utilizadas no estudo;

A segunda coluna representa: A forma como os dados coletados na coluna 1, vão ser processados e calculados tanto no modelo determinístico de produção de energia como nos softwares Pvsyst, PV*SOL e Neural Designer, com resultado em (KWh);

A terceira coluna representa: A análise dos dados obtidos na coluna 2 versus os resultados obtidos na coluna 4;

A quarta coluna representa: Os valores de energia produzidos na saída dos inversores das plantas solares estudadas em (KWh).

Obs. *Índice KT baseado na média histórica.

3.1 Fontes de Dados Meteorológicos

3.1.1 Estação Climatológica Presente nas Plantas Solares

Como forma de obter dados mais precisos e pontuais, a Chesf (Eletrobras) mantém nas plantas solares estudadas uma plataforma com os equipamentos climatológicos principais para aquisição de dados meteorológicos, a Figura 26 e descritos na Tabela 7, mostra uma estação própria da Chesf, que com os dados adquiridos nas estações meteorológicas próximas auxilia a gerar um panorama geral na região onde estão localizadas as plantas.

A torre climatológica é formada pelos seguintes componentes:

Figura 26 - Torre Climatológica Eletrobras - Chesf.



Fonte: Chesf, (2023)

Tabela 7 - Equipamentos Presentes na Planta Fotovoltaica.

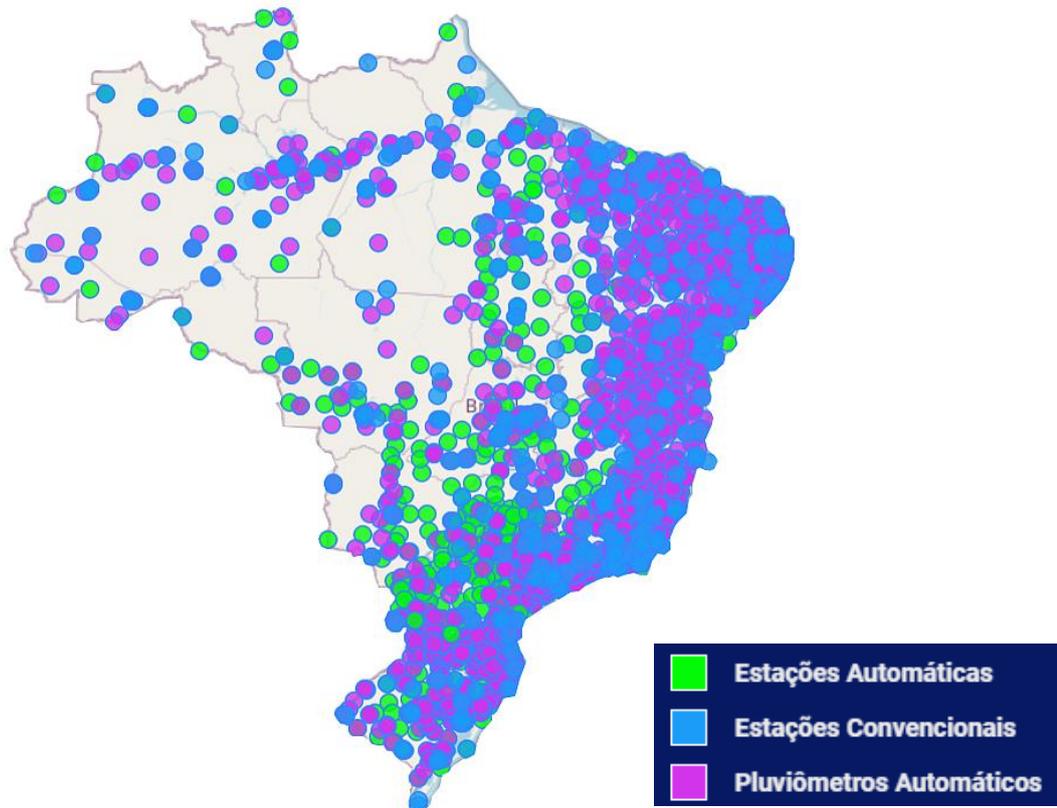
Nº	Instrumento	Quantidade	Variável medida
1	Anemômetro	1	Direção e velocidade do vento
2	Piranômetro primeira classe	2	Radiação global solar
3	Sensor de umidade e temperatura	1	Umidade e temperatura

Fonte: Chesf, (2023).

3.1.2 INMET

Mapa dinâmico Figura 27, contendo informações geradas pelas estações meteorológicas do INMET (Instituto Nacional de Meteorologia) e de instituições parceiras e que permite a sobreposição de diversas camadas de produtos meteorológicos, tais como imagens de satélites, modelos de previsão do tempo e avisos de tempo severo.

Figura 27 - Mapa Estações INMET.



Fonte: INMET, (2024) Adaptado pelo autor.

Estrutura padrão de uma estação meteorológica do Inmet e seu arranjo físico:

Anemógrafo, Anemômetro, Barógrafo, Barômetro de Mercúrio, Higrógrafo, Evaporímetro de Piche, Heliógrafo, Microbarógrafo, Piranógrafo, Piranômetro, Pluviógrafo, Pluviômetro, Psicrômetro, Tanque Evaporimétrico Classe A, Termógrafo, Termohigrógrafo, Termômetros de Máxima e Mínima, Termômetros de Solo. Tendo uma imagem de uma estação em seu arranjo normal da Figura 28, abaixo.

Figura 28 - Estação modelo INMET.



Fonte: INMET, (2024).

3.1.3 LABMET

Labmet (Laboratório de Meteorologia - ligado à Universidade Federal do Vale do São Francisco - UNIVASF), atua também nas atividades agrícolas da região e fornecendo a sociedade em geral, informações confiáveis sobre as condições de tempo e de clima. Deste modo foi montada uma estrutura moderna para monitoramento das condições do tempo, do clima e para realização de pesquisas agrometeorológicas na região semiárida, bem como apoiar a formação profissional dos alunos de Graduação e de Pós-Graduação em Engenharia Agrícola e áreas afins (Labmet, 2024).

O LabMet dispõe da seguinte estrutura: um laboratório no Campus de Juazeiro, equipado com uma estrutura computacional, duas estações meteorológicas automáticas, uma em Petrolina e outra em Juazeiro, bem como um conjunto de sensores e equipamentos que são utilizados em pesquisas de campo.

3.1.4 Dados Meteorológicos dos Locais Observados

Tabela 8 - Tabela Geral de Valores Meteorológicos das duas Localidades.

		Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
PETROLINA	TEMP	28	28	28	27	27	25	25	25	27	28	29	28
	PRECIP.	62,8	80,2	101,7	49,5	8	4,6	3	1,8	3,3	11,1	45,8	63,8
	KT	0,42	0,48	0,46	0,40	0,38	0,38	0,41	0,31	0,24	0,25	0,47	0,42
	UMID	58	63	67	70	64	61	60	53	48	48	50	54
	VENTO	23,4	21,4	20,5	20,6	22,4	23,6	25,4	26,4	25,4	24,2	22	21
	DIAS CHUVA	8	6	12	15	5	8	8	2	3	6	11	8
MESSIAS	TEMP	26	27	27	26	25	24	23	23	24	25	26	26
	PRECIP.	18,1	23,2	44,5	131,3	199,8	199,6	199,2	52,7	22,7	28,2	11,4	13,3
	KT	0,37	0,33	0,37	0,37	0,48	0,49	0,49	0,52	0,47	0,41	0,39	0,4
	UMID	75,9	70,4	66,9	78,5	84,9	75,4	65,1	75,8	83,6	82,1	79	78,7
	VENTO	24,8	23,6	20,9	19,8	18,8	21	21,5	23,1	22,2	24,1	26,8	25,4
	DIAS CHUVA	5	3	11	12	15	17	14	16	8	2	2	6

Fonte: Pereira et al. (2017).

Os valores da Tabela 8, estão agrupados para facilitar a observação e percepção das variações de forma histórica para as localidades analisadas. Temperatura, precipitação, índice KT, umidade, velocidade do vento e dias de chuva.

3.2 Período Analisado, Qualificação e Filtros dos Dados

Tabela 9 - Informações Geoclimáticas nas Plantas Fotovoltaicas.

Local	Latitude	Longitude	Altitude (m)	Nebulosidade Média anual (décimos)	Chuva Anual (mm)	Clima
Petrolina (PE)	9°06'23.3"S	40°26'31.7"O	385	0,5	430	Semiárido
Messias (AL)	9°24'00.6"S	35°50'26.0"O	104	0,5	944	Tropical Chuvoso

Fonte: Elaborado pelo Autor, (2024).

Para o estudo em questão, foram analisados dados meteorológicos já mencionados na Figura 25 e na Tabela 8, de radiação e coletados dados de equipa-

mentos de medição tanto de potência como meteorológicos das plantas solares da Eletrobras - Chesf, que fazem parte do estudo, listada suas localizações na Tabela 9.

O período analisado e proposto é o de 01/01/2023 até 31/12/2023, com intervalos horários de 01h (uma hora), conforme disponibilizado pelas estações meteorológicas e obtidos no sistema do INMET, LABMET e outras fontes de dados utilizadas no estudo. Considerando 13h de intervalo de variáveis, multiplicando por 365 dias referentes ao ano de 2023, vamos ter por cada item de entrada (por exemplo: temperatura, radiação, umidade, precipitação), um total de 4745 dados.

Levando em consideração os 7 itens estudados, totalizando no geral uma abrangência de 33215 a 37960 itens por cada planta analisada. Outro ponto importante do estudo foi analisar a localização das estações meteorológicas em relação as plantas solares, como meio de melhorar a precisão do estudo, como exemplifica a Tabela 10, com as respectivas distâncias.

Tabela 10 - Distância Estação - Planta e Período estudado.

Local	Estação escolhida	Distância da Estação até a planta (Km)	Período	Intervalo
Petrolina (PE)	LABMET	23	Jan-dez 2023	1h
Messias (AL)	INMET UFAL	12	Jan-dez 2023	1h

Fonte: Elaborado pelo Autor, (2024).

Observação, as plantas FV de Petrolina e Messias possuem estação solarimétrica própria, analisada e considerada para fins de comparação, uso e reposição de dados, conforme descrito e com imagem demonstrada na seção 3.1.1.

Para abordar a questão da atuação das aglomerações de água perto das plantas fotovoltaicas e a possibilidade das mesmas criarem um “microclima” perto das plantas FV estudadas, os estudos que abarcam a influência das massas d’água sobre os climas urbanos são raros e, segundo Manteghi, Limit e Ramaz (2015), estes estudos hipotéticos sobre o resfriamento em dias quentes nas cidades são poucos, resguardando ainda que estas oferecem resfriamento na direção da ventilação predominante. Assim como outra fonte de estudos no mesmo tema, de Souza, Mariano e Galvani (2018), em pesquisa realizada na cidade de Presidente Epitácio – SP, destacaram que a presença do reservatório da Usina Hidrelétrica Engenheiro Sergio Motta (Porto Primavera) não influencia o aumento ou decréscimo de temperatura e umidade do ar decréscimo de temperatura e umidade do ar, servin-

do apenas como elemento termorregulador hidrométrico.

Para finalizar, mais duas vertentes de estudos sobre o tema, a primeira na cidade de Shanghai, segundo Hongyu et. al. (2016), destacam que o efeito de arrefecimento do lago foi maior do que o de rio em virtude de maior “ilha” de refrigeração de água advinda desses corpos hídricos. Entretanto, destaca que a área vegetada e a minimização das superfícies impermeáveis devem ser levadas em consideração, gerando assim um efeito maior do efeito da massa d’água sobre o entorno imediato e conforme Masiero (2014), os estudos em São José do Rio Preto – SP,, demonstraram que a influência das massas de ar sobre o corpo hídrico beneficia o entorno imediato em até 1.000 m de distância entre o perfil hídrico e o elemento urbano, contudo a topografia e geometria urbana tendem a reduzir esse efeito.

Por esse motivo é reportada a distância das plantas de Petrolina (PE), que está localizada a 16 km do leito do Rio São Francisco. Outro ponto analisado, a distância da planta Messias para o litoral, que gira em torno de 37 km, sendo desconsiderada a possibilidade de microclima nessa planta em questão, embora temos que reconhecer que o clima tropical chuvoso possa aumentar consideravelmente os índices de precipitação e diminuir um pouco a temperatura.

A metodologia segue em obter os dados de irradiação solar global das duas bases de dados para as cidades listadas no presente estudo, e compará-las por meio de gráficos e indicadores estatísticos. Essas cidades foram selecionadas devido possuírem estações meteorológicas locais e plantas solares da Eletrobras - Chesf.

A base do INMET divulga um histórico com apenas 365 dias, contados da corrente data de pesquisa. Como os sensores são susceptíveis a erros, algumas informações de radiação ou meteorológicas podem não estar presentes no banco.

Neste caso, é indicado que a base dos dados observados e selecionados diante das fontes meteorológicas, passe por um pré-tratamento que corresponde:

- Filtrar os valores de acordo com o horário de 05h00 até 18h00, correspondente com o ciclo solar e a radiação máxima aproveitável de acordo com a base de geração anual de todas as usinas solares reguladas pela ONS, ONS (2024);
- Filtrar nessa faixa de horário a presença de dados nulos, discrepantes e negativos;
- Preparar os arquivos CSV e TXT, para importar nos aplicativos utilizados nesse estudo;
- Nos softwares testados, como forma de auxílio para os usuários, algumas interfaces desses softwares analisam os dados importados e em caso de observar dados nulos,

discrepantes ou negativos. Esses softwares geram logs e mensagens de alerta ou erro e em alguns casos expõem quais dados estão errados, fazendo com que o usuário revise os dados;

- Para o PVsyst e Neural Designer foi utilizada uma base de dados de entrada diária enquanto o PV*SOL uma base de dados de entrada mensal. (Fonte de dados descritas na Tabela 10).
- Com o aprofundamento nos dados e literatura que trata do mesmo tema, também auxilia a observar e melhorar o refino da fonte de dados meteorológicos analisada.
- Estimar dados faltantes ou discrepantes por meio do modelo de Angstrom-Prescott conforme informações e métodos a seguir:

A existência de uma relação direta entre a radiação global diária e a insolação foi sugerida inicialmente por Kimball em 1919. Posteriormente, outros pesquisadores passaram a desenvolver modelos estatísticos que permitem estimar a radiação solar que chega à superfície a partir dos dados de insolação. O primeiro modelo com esse propósito foi desenvolvido por Angström (1924). Em seguida, Prescott (1940) simplificou o modelo de Angström, permitindo que, a partir dos coeficientes linear e angular da equação de regressão linear simples entre a razão de insolação e de radiação solar global, pudesse estimar a radiação solar global baseada nos dados de insolação. O modelo denominado de Angström Prescott, teve como base adaptações em função de condições climáticas locais e vem sendo utilizado universalmente conforme estudos (Buriol et al., 2012; Okonkwo e Nwokoye, 2014, Escobedo et al., 2012; Suehrcke et al., 2013; Jamil e Siddiqui, 2017; Fan et al., 2019).

A equação de Angström-Prescott pode ser utilizada com base em dados diários, quinzenais, mensais, sazonais e anuais e seus coeficientes (a e b) devem ser ajustados localmente e para diferentes épocas do ano, a fim de melhor representarem a variação da radiação em função do brilho solar. O cálculo dos coeficientes a e b da equação de Angström-Prescott (Prescott, 1940) para os períodos anual, sazonal e mensal foram obtidos a partir de análise de regressão linear, com o auxílio de uma planilha eletrônica desenvolvida especialmente para essa finalidade, os coeficientes da equação de regressão linear “a” e “b” de Angstrom-Prescott foram estimados utilizando-se valores diários da série de 2020 a 2023, considerando as relações n/N e H/H_0 como as ordenadas x e y, respectivamente, nas escalas mensal e anual. A Equação 6, utilizada nos modelos foi a de Ångström-Prescott (PEREIRA et al., 2002) escrita da seguinte forma:

$$H = H_o (a + b \cdot n/N) \quad (1)$$

Eq.6

Onde:

H - Irradiação solar diária (Wh/m²); Ho - Irradiação incidente no topo da atmosfera (Wh/m²); n - número de horas diárias de brilho solar (h); N - número máximo possível de horas de sol diárias (h); "a" e "b" - coeficientes da equação de regressão linear. Os valores diários de "Ho" e "N" foram calculados com base na latitude do local e no dia do ano, que vai de 1 a 365 ou 366, se o ano for bissexto (ALLEN et al., 1998).

Na Tabela 11, constam os coeficientes utilizados no modelo Angstron-Prescott e os respectivos dados discrepantes (usando como referência valores de outliers de acordo com os quartis encontrados, valores negativos ou extremamente elevados e fora da faixa esperada pelas observações dos dados) e nulos que o modelo auxiliou a suprir.

Tabela 11 - Coeficientes mensais no modelo Angström-Prescott e de determinação para Messias e Petrolina

Planta Fotovoltaica Messias -AL					
Mês	Coeficiente a	Coeficiente b	R ²	Dados Discrepantes	Dados Nulos
Junho	0,4393	0,3945	0,8186	09	3
Novembro	0,4938	0,2645	0,8397	14	-
Dezembro	0,4932	0,3001	0,7452	19	-
Planta Fotovoltaica Petrolina - PE					
Maio	0,4870	0,4232	0,7302	08	-

Fonte: Elaborado pelo Autor, (2024).

3.3 Detalhes das Plantas Analisadas

Em Messias II, a minigeração distribuída conectada à rede de distribuição de energia elétrica através de um sistema fotovoltaico de 700 kW, composto por 2618 módulos com potência de 335 Wp cada, totalizando 877,03 kWp. O sistema é composto de módulos fotovoltaicos de fabricação Canadian Solar, modelo CS6U-335P, e por 7 inversores, com potência de 100kW cada, do modelo PVS-100-TL do fabricante ABB, totalizando 700 kW, caracterizado como autoconsumo remoto. Baseado no consumo total médio mensal das instalações da Chesf ligadas ao Sistema de Distribuição da Equatorial Energia Alagoas, que em média totaliza 1474 MWh/mês, e, considerando as características e as condições atmosféricas locais na região de Messias/AL, dimensionou-se o sistema de geração FV levando em consideração esses fatores conforme memorial elaborado por Resende (2021) e descrito na Tabela 12.

Tabela 12 - Configuração do Sistema Fotovoltaico em Messias II (AL)

Especificações	Valores
Potência Nominal da Planta:	700 kWca
Potência fotovoltaica total instalada:	877,03 kWp
Área total da central geradora:	10000 m ²
Quantidade Total de Módulos	2618
Potência por módulo:	335 Wp
Quantidade de Inversores:	07
Modelo do inversor utilizado	PVS-100-TL
Fabricante do inversor	ABB
Potência unitária inversores (kVA):	100
MPPT's por inversor (entradas):	06
Strings por entrada:	$5 \times 4 + 1 \times 2 = 22$ strings/inversor
Total de Strings:	$7 \times 22 = 154$
Fabricante do módulo	Canadian Solar
Modelo do módulo utilizado	CS6U-335P
Eficiência do módulo	17,25 %
Módulos por String:	17

Fonte: Resende, (2021).

Figura 29 - Localização Planta Fotovoltaica Messias.



Fonte: Google Earth, (2024) Adaptado pelo autor

As placas solares foram instaladas diretamente em suportes fabricados em aço galvanizado à fogo, implantadas no solo. O suporte justado para o ângulo de 10°. A

conversão da radiação solar em energia elétrica, em corrente contínua, feita por meio de módulos fotovoltaicos do tipo policristalino de alta eficiência (17,25%). A conversão da corrente contínua em alternada é realizada por meio de inversores de frequência, concebidos especificamente para sistemas de geração fotovoltaicos. A planta FV está localizada no Endereço: Rodovia BR 104, km 74, s/n Zona Rural - Messias/AL - CEP 57.990-000, conforme visualizado anteriormente na Figura 29.

Planta Fotovoltaica CRESP Petrolina (PE)

Usina Solar Fotovoltaica com potência instalada de 2508 kWp, considerando os dados de placa individuais a 25°C e 1000 W/m². Sendo composto por um total de 7600 módulos fotovoltaicos conforme visualizado na Figura 30, com potência de 330 Wp cada um, mais especificações na Tabela 13 abaixo.

Tabela 13 - Configuração do Sistema Fotovoltaico CRESP Petrolina (PE).

Especificações	Valores
Potência fotovoltaica total instalada:	2508 kWp
Área total da central geradora:	25732 m ²
Quantidade Total de Módulos:	7600
Potência por módulo:	330 Wp
Quantidade de Inversores:	04
Fabricante do inversor	WEG
Modelo do inversor utilizado	SIW700-T600-33
Potência unitária inversores (kVA):	600
MPPT's por inversor (entradas):	06
Fabricante do módulo	Canadian Solar
Eficiência do módulo	16,97 %
Modelo do módulo utilizado	CS6U-330p
Módulos por String:	19

Fonte: Pereira, (2022).

Figura 30 - Localização Planta Fotovoltaica Petrolina.



Fonte: Google Earth, (2024) Adaptado pelo autor.

A instalação ocupa aproximadamente uma área de 25732 m² do terreno, estando distribuídos os módulos nos seguintes arranjos:

- Quadrante 1: 1976 módulos (6 x (16 strings x 19 módulos) + 8 strings x 19 mód)
- Quadrante 2: 1824 módulos (6 x (16 strings x 19 módulos))
- Quadrante 3: 1976 módulos (6 x (16 strings x 19 módulos) + 8 strings x 19 mód)
- Quadrante 4: 1824 módulos (6 x (16 strings x 19 módulos))

Cada quadrante tem seu respectivo inversor.

Os módulos fotovoltaicos foram instalados sobre as estruturas metálicas fixas montadas no solo, ajustados para o ângulo de 15°. Tais estruturas são calculadas para resistir às cargas de vento e suportar as condições meteorológicas adversas, minimizando a manutenção.

3.4 Métricas Estatísticas de Comparação Utilizadas

Para análise comparativa entre as bases de dados estudadas, foram utilizados métodos estatísticos que visam avaliar o grau de variabilidade dos dados em torno da média, para isso são utilizadas as medidas de dispersão como desvio médio, variância e desvio padrão. Além disso, o conjunto de dados médios e medianas são incluídos para representar o valor central do conjunto total de dados. A seguir são apresentados os métodos aplicados.

Quando analisamos dados que sugerem a existência de uma relação funcional entre duas variáveis, surge então o problema de se determinar uma função matemática que exprima esse relacionamento, ou seja, uma equação de regressão.

Ao imaginar uma relação funcional entre duas variáveis, digamos X e Y, estamos interessados numa função que explique grande parte da variação de Y por X. Entretanto, uma parcela da variabilidade de Y não explicada por X será atribuída ao acaso, ou seja, ao erro aleatório.

Quando se estuda a variação de uma variável Y em função de uma variável X, dizemos que Y é a variável dependente e que X é a variável explanatória (ou independente).

3.4.1 Médias

A média é dada pela soma de todos os elementos que estão sendo considerados, dividido pelo número de elementos n como mostrado na Equação 7.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad \text{Eq. 7}$$

3.4.2 Variância e Desvio Padrão Amostral

A variância e o desvio padrão amostral são métricas que indicam a dispersão dentro de uma amostra, ajudando a entender o grau de afastamento dos valores em relação à média. De acordo com Machado (2017), a variância aplicada em Big Data demonstra o quanto os valores estão dispersos em relação à média aritmética, que em geral é o valor esperado. O desvio padrão amostral é dado pela Equação 8 e a variância amostral é o resultado obtido pelo desvio padrão ao quadrado.

$$dp(x) = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad \text{Eq. 8}$$

3.4.3 Mediana

A mediana é uma medida de posição que separa o conjunto de dados ordenados exatamente na metade, deixando 50% dos valores abaixo e 50% acima.

3.5 Métricas R, MAE, MAPE, MSE e RMSE

Alguns projetos comuns de aprendizado de máquina ou ciência de dados são voltados para a classificação. Além disso, existem modelos de regressão que visam prever valores numéricos.

Ao trabalharmos com modelos de categorização, as métricas comparam se as classes foram adequadamente previstas ou não. Ao empregarmos a regressão, isso se torna impraticável, uma vez que estamos lidando com números, frequentemente com casas decimais, e não apenas 0 ou 1. Assim, a abordagem principal das métricas de regressão se baseia na discrepância entre o valor real e o previsto, conforme evidenciado na Equação 9. Em que y simboliza o valor verdadeiro, enquanto \hat{y} corresponde a valores que foram previstos.

$$e = y - \bar{y} \quad \text{Eq. 9}$$

Equação 9 - Equação que demonstra o cálculo da diferença entre o valor real e a previsão. Na equação “e” é o desvio, enquanto que \hat{y} é o valor predito e y é o valor real.

3.5.1 Erro Médio Absoluto

O erro médio absoluto (MAE - do inglês Mean Absolut Error), segundo a Equação 10, a média da diferença entre o valor real e o previsto é medida. No entanto, devido à presença de valores positivos e negativos, adiciona-se um módulo à diferença desses valores. Ademais, essa métrica não sofre influência de valores divergentes - os chamados outliers.

$$\text{MAE}(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad \text{Eq. 10}$$

Equação 10 - Erro médio absoluto. Esta equação há o cálculo da média da diferença entre o valor predito \hat{y} e o real y . Quanto mais baixo o resultado de MAE, logo melhor são os resultados preditos pelo modelo de machine learning.

3.5.2 Erro Percentual Absoluto Médio

O erro percentual absoluto médio (MAPE - do inglês Mean Absolute Percentual Error) retrata a métrica que apresenta a porcentagem de erro em relação aos valores reais. Na Equação 11, ilustra o cálculo de MAPE que se assemelha bastante ao MAE, mas com o acréscimo de uma divisão por $|y|$. Então se o resultado de MAPE equivale a 40% mostra que o nosso modelo faz previsões que em média a diferença entre o valor previsto e o real equivale a 40% do valor real quer seja para mais ou para menos.

$$\text{MAPE}(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\max(\epsilon, |y_i|)} \quad \text{Eq.11}$$

Equação 11 - Erro percentual absoluto médio. Esta equação, o cálculo do valor da média da divisão entre a diferença entre o valor real e o previsto sobre o valor real.

A divisão por zero é evitada, utilizando o valor de ϵ para ser utilizado na situação do valor de y seja 0.

Ao analisar a Equação 11, nota-se que caso o valor de y seja 0, ocorrerá um erro, devido a divisão por zero. Por isso que a biblioteca scikit-learn utiliza o artifício de colocar um valor muito pequeno, representado por ϵ , cujo valor é $2,220446049250313e-16$. A métrica MAPE é uma das métricas mais usadas para reportar a performance do modelo, trazendo uma compreensão mais abrangente do resultado de MAE.

3.5.3 Erro Quadrático Médio

O erro quadrático médio (MSE - do inglês Mean Squared Error) esquematizado na Equação 12, é uma métrica que calcula a média de diferença entre o valor predito e o real, como a métrica MAE. Contudo, em vez de utilizar o módulo da diferença entre os valores de y e \hat{y} , nesta métrica, a diferença é elevada ao quadrado. Assim, penalizando valores que sejam significativamente distintos entre o previsto e o observado. Portanto, um valor elevado de MSE indica que o modelo não teve um desempenho satisfatório nas previsões.

$$\text{MSE}(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \text{Eq. 12}$$

Apesar de sua ideia poderosa, a métrica MSE apresenta um problema de interpretação. Por haver a elevação ao quadrado, a unidade fica distorcida, em outras palavras, se a unidade medida for metros (m), o resultado será em m^2 . Por isso que uma adaptação da MSE é a RMSE que será apresentada abaixo.

3.5.4 Raiz do Erro Quadrático Médio

A raiz do erro quadrático médio (RMSE - do inglês, Root Mean Squared Error) é basicamente o mesmo cálculo de MSE, possuindo ainda a mesma premissa de penalização entre grandes diferenças do valor previsto e o real. Porém, para lidar com o problema da diferença entre unidades, é aplicada a raiz quadrática como demonstrado na Equação 13. Sendo assim, a unidade fica em escala igual à do dado original, resultando em uma melhor interpretação do resultado da métrica, (Bruce, 2019).

$$\text{RMSE}(y, \hat{y}) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad \text{Eq. 13}$$

Embora o valor tenha a mesma unidade, ele não acomete de se assemelhar ao resultado encontrado de MAE, demonstrando como os outliers podem estar afetando

nas previsões deste modelo. A sua interpretação pode seguir a mesma lógica, onde o resultado da métrica apresentando, por exemplo, 80,0 m, significa que o modelo pode estar errando em 80,0 m para mais ou para menos. Por esse motivo, esta métrica pode ser uma boa opção quando é necessário ter uma avaliação mais aprimorada sobre as previsões do modelo.

3.5.5 Correlação de Pearson

Para compreender os efeitos de alguns parâmetros meteorológicos na geração de energia solar fotovoltaica, uma das ferramentas que podem ser utilizadas é a Correlação de Pearson (R), que é uma medida de associação linear entre variáveis e é dada pela Equação 14. O coeficiente de correlação de Pearson é um teste que mede a relação estatística entre duas variáveis contínuas. Se a associação entre os elementos não for linear, o coeficiente não será representado adequadamente. É um método utilizado para avaliar uma possível relação bidirecional entre os pares de variáveis (Mukaka, 2012).

$$(R) = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad \text{Eq. 14}$$

Onde:

n - Número de amostras. y_i - Amostra da variável y. \bar{X} - Média da variável x.
 x_i - Amostra da variável x. \bar{Y} - Média da variável y.

A constante (R) é definida no intervalo (-1,1). O sinal indica direção negativa ou positiva do relacionamento e o valor absoluto sugere a força da relação entre as variáveis. No outro oposto, uma correlação de valor zero indica que não há relação linear entre as variáveis. Suas relações e forças estão demonstradas na Tabela 14.

Tabela 14 - Interpretação dos Coeficientes de Correlação de Pearson.

Coeficiente	Relação
± 0,90 a ± 1,00	Correlação positiva (negativa) muito alta
± 0,70 a ± 0,90	Alta correlação positiva (negativa)
± 0,50 a ± 0,70	Correlação positiva (negativa) moderada
± 0,30 a ± 0,50	Baixa correlação positiva (negativa)
± 0,00 a ± 0,30	Correlação insignificante

Fonte: Sales, (2015).

3.6 Intervalo de Confiança

Segundo a abordagem frequente, um intervalo de confiança para um parâmetro populacional específico indica um conjunto de valores que são consistentes com os dados obtidos da amostra, associados a um certo nível de confiança. Esse parâmetro pode ser, por exemplo, a média de uma distribuição, o risco relativo, a razão de chances, a variância, entre outros. O cálculo desse intervalo é um dos principais resultados em uma análise estatística. O intervalo de confiança por exemplo de 95% (IC 95%), indica a região onde se tem uma confiança de 95% de que cubra o valor verdadeiro do parâmetro populacional. Conforme Freire (2021), podemos interpretar o intervalo de confiança da seguinte forma: Dado um nível de confiança estabelecido a priori $(100 - \alpha) \%$, temos uma confiança de $(100 - \alpha) \%$ que o IC contenha o real valor do parâmetro estudado. Essa confiança deve ser interpretada no sentido de que, se repetíssemos o estudo um número infinito de vezes e, em cada vez, calculássemos o IC, em $(100 - \alpha) \%$ das vezes o IC conteria o real valor do parâmetro estudado.

3.7 Modelo determinístico de Geração de Energia Fotovoltaica

Devido a vários fatores, tais como temperatura da célula, época do ano, velocidade do vento, temperatura do ambiente, posição geográfica, determinar com precisão a produção de energia da célula fotovoltaica é complicado. Inclusive a eficiência da célula tende a diminuir com o aumento da temperatura da mesma, influenciado diretamente na potência de saída.

Segundo Cherif e Belhadi (2012), a potência instantânea (P_{inst}) pode ser calculada através da Eq. 15, sendo P_{max} a potência do módulo apresentada no manual do mesmo, f_{pv} é o fator de perdas, α_p é coeficiente de temperatura do módulo, μ_{Voc} (Coef. Temp. Tensão de Circuito Aberto) e V_{pm} (Tensão de Máxima Potência) determinado pela Eq. 16, $G_T S_{TC}$ é a irradiância nas condições padrão (1000 W/m^2) e G_i é a irradiância instantânea (W/m^2) incidente no módulo. $T_{C,STC}$ é a temperatura da célula FV nas condições padrão (25°C) e T_C é a temperatura instantânea da célula ($^\circ\text{C}$).

$$P_{inst} = P_{max} \cdot f_{pv} \cdot \frac{G_i}{G_T S_{TC}} \cdot [1 + \alpha_p (T_C - T_{C,STC})] \quad \text{Eq. 15}$$

$$\alpha_p = \frac{\mu_{Voc}}{V_{pm}} \quad \text{Eq. 16}$$

Com os dados obtidos, multiplica-se pela área dos módulos (m^2), sua eficiência de fábrica e pelo espaço temporal utilizado nos estudos (faixa de horário onde há a incidência de raios solares – Seção 3.2), com a soma desses diversos resultados até obter a média diária de geração e por conseguinte fazer uma base de dados anual.

3.8 Perdas de um Sistema Fotovoltaico

Para o presente estudo foram consideradas algumas perdas típicas de um sistema fotovoltaico, que está sujeito a diversas condições que podem causar perdas na geração. Uma grande variedade de variáveis pode ser calculada, enquanto outras são de grande complexidade. Sendo assim, são apenas estimativas. As perdas podem ser causadas desde o gerador fotovoltaico até o ponto de conexão à rede, passando pelas perdas na instalação e no sistema de condicionamento de energia. Para reforçar esses dados, podemos citar algumas fontes, como o de Kymakis, Kalykakis, e Papazoglou, (2009), em seus estudos, chegaram a uma perda média de 7,12 % devido a temperatura da célula.

E as causas de degradação no módulo fotovoltaico podem ser geradas em função de vários fatores. O desgaste natural, ao longo de sua utilização, é inevitável e certamente é um dos fatores de perdas no gerador fotovoltaico. Potência é dissipada na fiação elétrica e os condutores possuem papel importante em um sistema fotovoltaico. Parte dos condutores ficam expostos ao Sol e chuva, portanto, deve possuir proteção ultravioleta (UV). É conveniente dimensionar as seções dos condutores para que a queda de tensão seja inferior a 1,5% (Verma e Singhal, 2015).

No estudo não foram consideradas perdas por sombreamento, devido a inexistência de qualquer objeto que possa causar esse tipo de perda nas proximidades das plantas estudadas.

Quando a conexão à rede é feita, utilizando transformador de potência, este também contribui com uma perda geralmente de 2% (Almeida, 2012). As condições da rede podem impactar na potência injetada na rede pelo gerador fotovoltaico, uma vez que os inversores dependem da tensão, da frequência e da impedância de referência da rede.

E conforme já explanado anteriormente segundo Ipea-Pvps (2022), conforme estudos podemos considerar as perdas por sujidade anual em torno de 3% a 4%. A projeção de sombra em 50% de uma única célula reduz em 30% a produção de energia. Mesmo existindo uma limpeza natural do vidro, devido à chuva e vento, ainda

pode haver um acúmulo de sujeira que representa uma perda de cerca de dez por cento (10 %). Em contato com os responsáveis pela manutenção das plantas fotovoltaicas, foi reportada existência de um plano periódico de manutenção e limpeza dos módulos como meio de diminuir os efeitos da sujidade.

A sujidade é provocada por fatores como deposição de poluição e partículas que provocam grande impacto na eficiência dos painéis, especialmente em períodos longos de estiagem, podendo chegar até 30% de perda (Araújo, 2018). O termo sujidade refere-se aos elementos que se depositam nos módulos fotovoltaicos e que ocasionam a diminuição da absorção de radiação, como, por exemplo, neve em locais frios, poeira, folhas de plantas, pólen de flores e excrementos de pássaros. A perda de potência na geração está diretamente relacionada à quantidade de sujidade presente nos módulos fotovoltaicos (Maghami,2016).

E no quesito perdas dos inversores foram utilizadas nos cálculos as informações presentes nos manuais do fabricante. As causas de degradação no módulo fotovoltaico podem ser geradas em função de vários fatores. O desgaste natural, ao longo de sua utilização, é inevitável e certamente é um dos fatores de perdas no gerador fotovoltaico. De acordo com Wohlgemuth e Kurtz (2012), estima-se uma perda média anual de 0,5 % para células de silício cristalino. Mesmo estudo direcionado por Luiz *et al.* (2022), o efeito da degradação dos módulos de silício policristalino testados mostrou que os módulos em testes apresentaram uma degradação condizente ao declarado pelo fabricante, cerca de 0,67% ao ano.

Na Tabela 15 abaixo está disposta os tipos de perdas consideradas no presente estudo e os valores utilizados como referência nos testes do presente estudo (sublinhado quando se tem uma faixa de valores).

Tabela 15 - Tipos de Perdas e valores utilizados como referência

Tipo de Perda Considerada	Valor utilizado nos testes
Perda por Temperatura da Célula	7,12%
Perda de Cabos	1,5%
Perdas de conexão à rede	2%
Perda por Sujidade	<u>3</u> a 4%
Perda de Degradação	0,5% e <u>0,67%</u> (manual fabricante)

Fonte: Citadas na seção 3.8.

4 RESULTADOS E DISCUSSÃO

Nesta seção são analisadas as saídas dos softwares de dimensionamento, simulação e redes neurais para o uso em plantas fotovoltaicas, em especial as plantas solares do CRESP – Centro de Referência em Energia Solar de Petrolina (PE) e da Planta Solar Messias II (AL), pertencente à Eletrobras. Nas quatro primeiras subseções, é feita uma caracterização estatística das entradas e saídas do modelo determinístico, PVsyst, PV*SOL e Neural Design. Na subseção 4.6 é feita uma comparação entre os resultados dos softwares citados e entre trabalhos de outros autores.

4.1 Modelo Determinístico Planta Fotovoltaica CRESP – Petrolina (PE)

Na Tabela 16, está demonstrada a produção energética em MWh no decorrer dos últimos quatro anos na planta FV do CRESP Petrolina, embora ênfase do presente estudo, focou nas atividades de produção de energia da planta no ano de 2023.

Tabela 16 - Energia Gerada Anualmente Petrolina.

	2020	2021	2022	2023
Energia Gerada (MWh)	3428,77	3822,51	3467,34	3796,64

Fonte: Chesf, (2023).

Tabela 17 - Comparativo Produção Energia Estimada x Medida em Petrolina (kWh/ano).

Mês	kWh Estimado	kWh Medido	Erro % Est./Med	Status	GHI	LAT	Temp. °C	Nebul. %
JAN	127,149	127,022	0,0999	MAIOR	6,38	6	28	42,4
FEV	126,684	117,107	7,5599	MAIOR	6,16	5,96	28	48,9
MAR	116,045	119,261	-2,771	MENOR	6,02	6,03	28	46,8
ABR	109,130	125,403	-14,91	MENOR	5,24	5,44	27	40,6
MAI	92,007	106,240	-15,47	MENOR	4,82	5,16	27	38,6
JUN	94,128	102,865	-9,282	MENOR	4,57	4,97	25	38,2
JUL	120,953	138,509	-14,51	MENOR	4,82	5,19	25	41,3
AGO	131,041	138,415	-5,627	MENOR	5,55	5,84	25	31,3
SET	145,512	141,722	2,6046	MAIOR	6,32	6,4	27	24,6
OUT	153,651	152,258	0,9067	MAIOR	6,4	6,24	28	25,4
NOV	143,208	122,045	14,778	MAIOR	6,5	6,16	29	47,4
DEZ	142,467	122,970	13,686	MAIOR	6,38	5,95	28	42,9

Fonte: Elaborado pelo Autor, (2024).

Na Tabela 17, está presente a produção de energia no decorrer do ano, tanto para a energia medida na saída dos inversores como a energia determinada pela fórmula de cálculo de potência de saída da PFV (Seção 3.8), considerando também o

efeito das perdas citadas na (Seção 3.8).

Conforme pode ser observado na Tabela 17, os dados de produção de energia (tanto estimada como medida) apresentaram uma queda nos meses com menor radiação (meio do ano), conforme esperado. Nos meses de março a agosto houve um declínio da energia estimada em relação a medida, indicando que o modelo determinístico tende a subestimar no inverno e sobrestimar no verão.

A Tabela 18 traz várias métricas da estatística descritiva à fim de caracterizar alguns aspectos das séries de dados medidos e estimados via modelo determinístico.

Tabela 18 - Métricas Estatísticas Petrolina.

	kWh/m² Estimado	kWh/m² Medido
Média	4327,52	4147,44
Desvio Padrão	962,31	866,30
Variância	37,39	211,21
Coefficiente de Variação	22%	21%
Mediana	4402,73	4300,32
Valor Mínimo	1634,46	1225,00
Primeiro Quartil	3722,59	3640,71
Segundo Quartil	4389,41	4291,75
Terceiro Quartil	5130,39	4852,82
Valor Máximo	5903,27	5722,33
Soma (MWh/m ² /ano)	1579,55	1513,81

Fonte: Elaborado pelo Autor, (2024).

Os desvios-padrões das séries alcançaram valores de 866 a 962 kWh/m², sendo um reflexo das oscilações diárias da radiação, servindo para dar uma ideia do quão distante da média as amostras estão. A seguir, são explorados em gráficos e tabelas a comparação dos valores medidos e estimados.

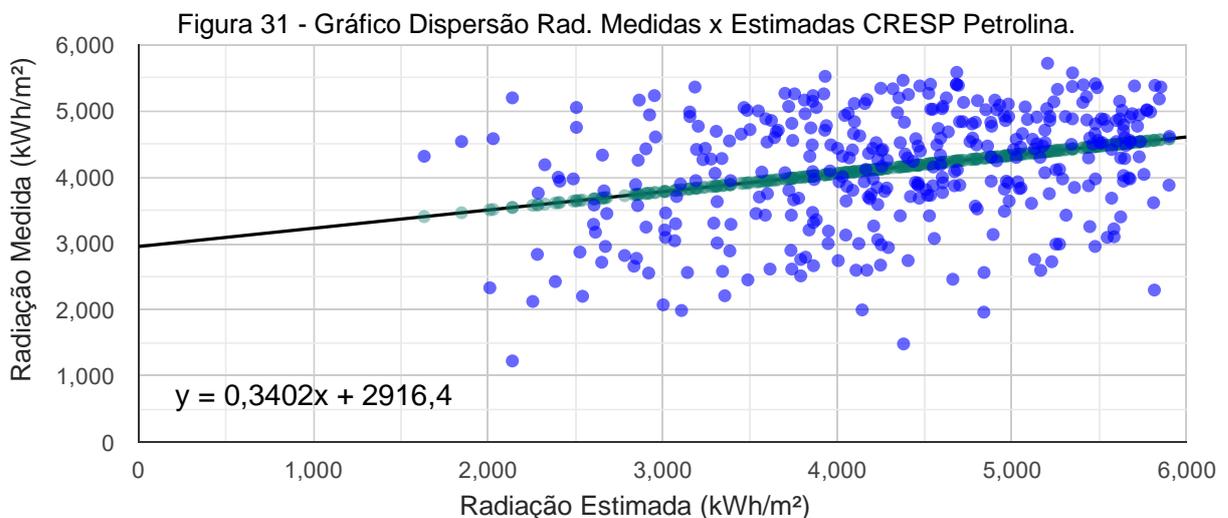
Tabela 19 - Coef. Correlação e métricas de Erro do modelo Determinístico para Petrolina.

Coeficiente	Resultado	
Coeficiente de Correlação	0,7794	
Erro médio Absoluto - MAE	868,22 kWh	
Erro Médio Absoluto porcentagem - MAPE	7,97 %	
Erro Quadrático Médio - MSE	107,847 kWh	
Raiz do Erro Quadrático Médio - RMSE	10,385 kWh	
Nível de Significância (alfa)	0,05	referência 95%
Intervalo de Confiança	99,05% (ESTIM.)	89,17%(MED.)

Fonte: Elaborado pelo Autor, (2024).

Ponto importante visto nessa comparação é a correlação entre os valores de kWh por m² medido e estimado que foi de 0,77 de acordo com a Tabela 19 sendo classificada como de força alta e positiva, MAPE de 7,97 % que mostra o erro em relação aos valores reais para mais ou para menos, e para os valores temos 99% de intervalo de confiança para valores estimados e 89% para os valores medidos. Os coeficientes de variação estão na faixa de 22%, representando a variabilidade dos dados observados.

Quanto a questão da dispersão, pela representação gráfica da relação entre duas variáveis e, dessa forma, a Figura 31 mostrou de forma gráfica os pares de dados numéricos estudados e sua relação, onde podemos classificar uma correlação de 0,77 como aceitável, com uma concentração substancial na faixa de 2000 a 6000 kWh/m². E o que foi reforçado pelo gráfico da dispersão, onde se demonstrou a concentração nesse trecho e os intervalos de valores bem delimitados e uma correlação positiva e forte de valores. Com poucos pontos fora da concentração próxima a linha de tendência central.



4.2 Modelo Determinístico Planta Fotovoltaica Messias II (AL)

Uma observação na fonte de dados da planta de Messias II que foi fornecida com dados baixados da plataforma GOODWE, é que a produção total dos inversores está em 7 x 25 kW cada e sendo um deles está fora de operação e não consta no somatório dos dados apresentados na Tabela 20, embora são 7 inversores com 100 kW cada conforme consta em projeto e estão trabalhando numa cota de produção energética abaixo do projetado.

Segundo cálculos elaborados para a planta FV e o memorial descritivo do projeto, segundo Resende (2021), são apresentadas as características técnicas dos módulos e inversores utilizados e, em seguida, relatório da compilação dos dados em simulação com utilização do software de dimensionamento de sistemas fotovoltaicos, o PVsyst, versão 6.35, indicando o valor total previsto da energia gerada pelo sistema projetado, o qual, resultou em um valor médio anual de 1431 MWh/ano.

Tabela 20 - Energia Gerada Anualmente Messias II.

	2020	2021	2022	2023
Energia Gerada (MWh)	122,67	72,51	107,08	118,19

Fonte: Chesf, (2023).

Tabela 21 - Comparativo produção energia estimada x Medida em Messias II (kWh/m²/ano).

Mês	kWh Estimado	kWh Medida	Erro % Est./Med.	Status	GHI	LAT	Temp. °C	Nebul. %
JAN	132,84	111,65	15,952	MAIOR	5,87	5,53	26	37,6
FEV	114,73	95,96	16,364	MAIOR	5,83	5,64	27	33
MAR	121,97	109,10	10,549	MAIOR	5,84	5,85	27	37,3
ABR	102,57	95,93	6,4748	MAIOR	5,06	5,25	26	37,2
MAI	92,13	89,71	2,6251	MAIOR	4,23	4,52	25	48,8
JUN	76,22	75,07	1,5095	MAIOR	3,9	4,21	24	49,3
JUL	85,18	89,69	-5,2984	MENOR	4	4,3	23	49,3
AGO	98,30	88,91	9,5544	MAIOR	4,57	4,79	23	52,6
SET	101,81	89,34	12,2464	MAIOR	5,39	5,45	24	47,2
OUT	119,85	101,21	15,5538	MAIOR	5,67	5,53	25	41,4
NOV	104,48	100,23	4,0657	MAIOR	6,16	5,84	26	39,8
DEZ	125,86	121,94	3,1121	MAIOR	6,11	5,7	26	40

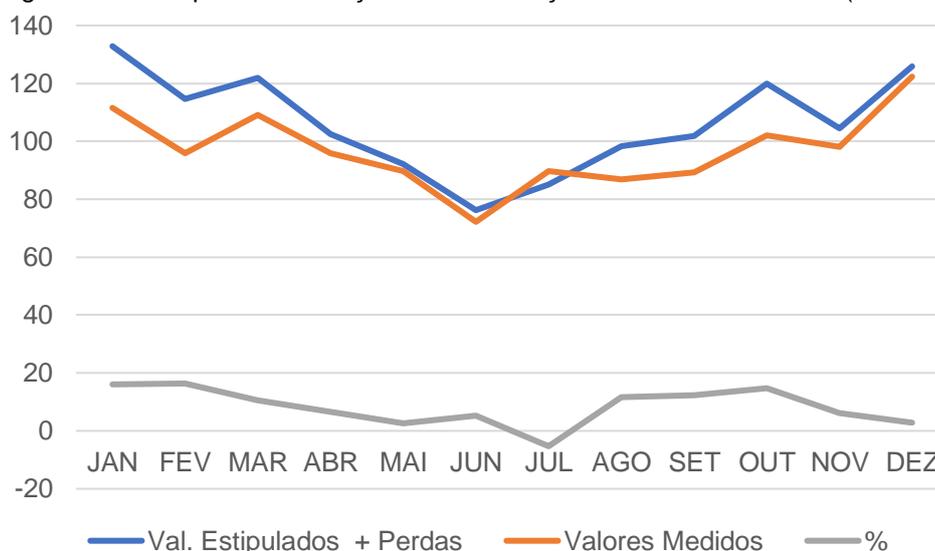
Fonte: Elaborado pelo Autor, (2024).

Em relação a Tabela 21, conclui-se que o mês de junho, apresentou um valor de radiação estimada menor do que a medida, no restante dos meses isso não é observado. Um fato interessante é uma queda na radiação nos meses de junho e julho e um pico de nebulosidade que já vem crescente desde maio e tem máxima em agosto, que também coincidiu com o período chuvoso. Os gráficos 32 e 33 a seguir, afirmam essa tendência, inclusive é observado no gráfico 33, onde nos meses do meio do ano em questão a linha laranja que representa a nebulosidade tem um aumento significativo, em contrapartida diminui as radiações GHI e LAT.

Na aba “status” da Tabela 21, retorna “MAIOR” ou “MENOR”, na comparação dos valores estimados em relação aos valores medidos. Nesse caso mostra-se que

os valores estimados tiveram em sua maioria valores acima dos valores medidos. E a aba com o símbolo “%” especifica o quanto esse valor ficou maior em termos percentuais presente na Figura 32 também, na linha na cor cinza, cabe ressaltar que nos meses iniciais do ano e os posteriores ao inverno apresentaram valores maiores percentuais devido às altas na radiação e a incidência do verão nordestino.

Figura 32 - Comparativo Medição Real x Medição Estimada Messias II (kWh/m²/ano)



Fonte: Elaborado pelo Autor, (2024).

Tabela 22 - Coef. Correlação e métricas de Erro do modelo Determinístico para Messias II.

Coeficiente	Resultado
Coeficiente de Correlação	0,892748
Erro médio Absoluto - MAE	498,81 kWh
Erro Médio Absoluto porcentagem - MAPE	8,44%
Erro Quadrático Médio - MSE	138,145 kWh
Raiz do Erro Quadrático Médio - RMSE	11,754 kWh
Nível de Significância (alfa)	0,05 referência 95%
Intervalo de Confiança	95,53%(ESTIM.) 84,12% (MED.)

Fonte: Elaborado pelo Autor, (2024).

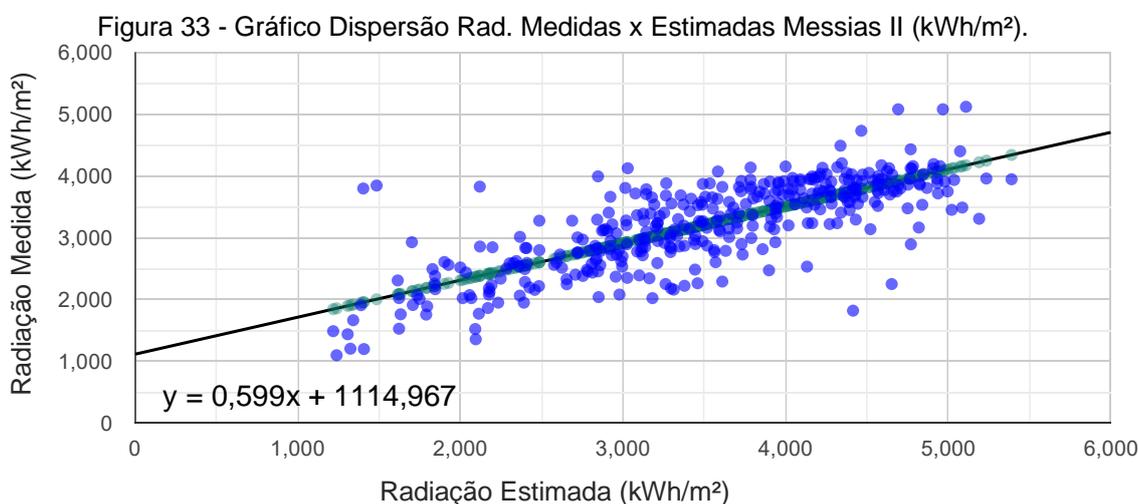
Ponto importante visto nessa seção é a correlação entre os valores de kWh por m² medido e estimado que foi de 0,89 de acordo com a Tabela 22, sendo classificada como de força alta e positiva, na Tabela 22, o MAPE de 8,44 % que mostra o erro em relação aos valores reais para mais ou para menos, e para os valores temos 95,53 % de intervalo de confiança para valores estimados e 84,12 % para os valores medidos. Os coeficientes de variação estão na faixa de 22% a 27%, representando a variabilidade dos dados observados, conforme resultados apresentados na Tabela 23.

Conforme os valores apresentados na Tabela 23, o desvio padrão que gira em torno de 718 a 928 kWh/m² para mais e para menos. Vale ressaltar o gráfico da dispersão mostrado na Figura 33 abaixo, com uma concentração na faixa concentração substancial na faixa de 2000 a 5000 kWh/m².

Tabela 23 - Métricas Estatísticas Messias II.

	kWh/m ² Estimado	kWh/m ² Medido
Média	3495,71	3210,24
Desvio Padrão	928,08	718,93
Variância	294,52	153,19
Coefficiente de Variação	27%	22%
Mediana	3534,42	3295,79
Valor Mínimo	1216,69	1096,52
Primeiro Quartil	2886,84	2728,32
Segundo Quartil	3534,42	3295,79
Terceiro Quartil	4249,62	3788,27
Valor Máximo	5389,71	5126,34
Soma (Mwh/m ² /ano)	1275,93	1171,74

Fonte: Elaborado pelo Autor, (2024).



Fonte: Elaborado pelo Autor, (2024).

4.3 Resultados Obtidos com o Software PVsyst

4.3.1 Dados Gerais - Planta FV CRESP Petrolina (PE)

A Tabela 24 foi retirada do PVsyst e traz, além dos valores de energia produzida (objeto do presente estudo), os valores de irradiância média diária.

Tabela 24 - Balanços e Resultados Principais Petrolina.

Ano	GHI kWh/m ²	DHI kWh/m ²	T_Amb °C	GHI Inc kWh/m ²	GHI Efe. kWh/m ²	E Efet. MWh	E_Inj. MWh	PR
Janeiro	223,4	67,40	28,43	234,0	225,8	455,4	444,6	0,758
Fevereiro	174,0	71,90	26,26	174,7	168,0	347,7	338,8	0,773
Março	221,0	52,70	28,95	208,5	200,6	408,3	397,9	0,761
Abril	198,4	45,70	28,44	173,7	165,8	344,0	335,6	0,770
Maio	152,2	62,50	25,99	129,2	122,3	262,5	254,3	0,785
Junho	141,0	50,50	24,67	115,2	108,9	236,2	228,4	0,791
Julho	149,5	58,20	23,81	125,6	119,0	258,7	250,9	0,796
Agosto	174,0	60,20	23,72	151,1	144,0	309,7	301,1	0,794
Setembro	197,7	61,20	26,16	182,2	174,7	364,9	356,3	0,780
Outubro	204,0	63,80	27,27	199,7	192,6	396,0	386,6	0,772
Novembro	207,7	63,70	26,80	213,9	206,8	421,1	410,3	0,765
Dezembro	190,9	74,50	28,40	199,7	192,9	393,6	383,1	0,765
Anual	2233,8	732,3	26,58	2107,6	2021,4	4198	4087,8	0,773

Fonte: PVsyst, (2024) Adaptado pelo autor.

Legenda:

GHI - Irradiação horizontal total.

T_Amb - Temperatura ambiente.

DHI - Irradiação difusa horizontal.

E EF - Energia efetiva à saída.

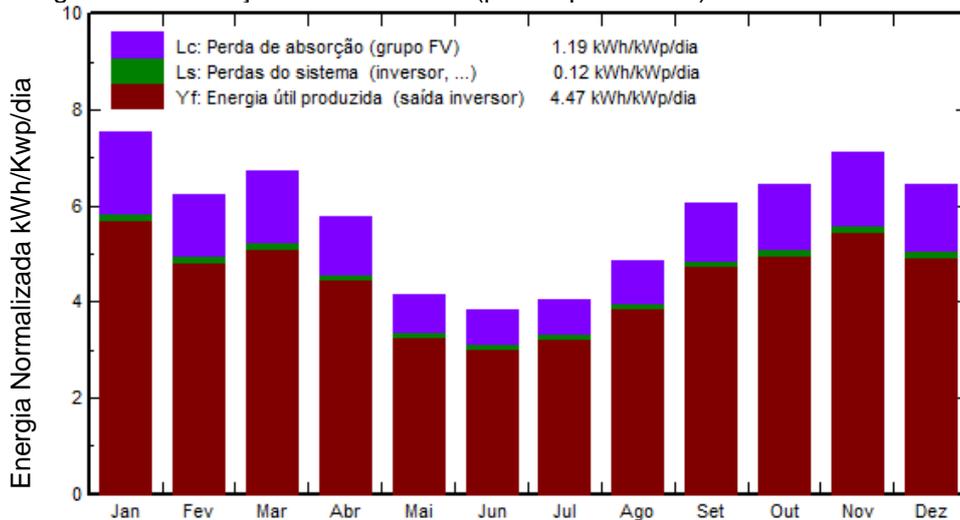
E_INJ - Energia injetada na rede.

PR - Índice de performance.

GHI EF - Global efetivo, p/ IAM e sombras.

GHI Inc - Ghi incidente.

Figura 34 - Produções Normalizadas (por kWp instalado): Potência Nominal 2508 kWp.

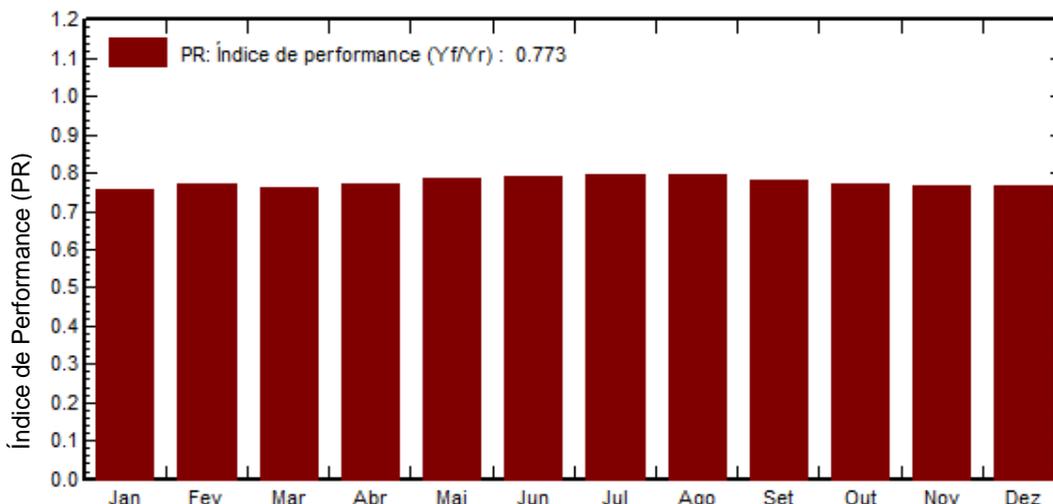


Fonte: PVsyst, (2024) Adaptado pelo autor.

O gráfico da Figura 34 retrata a produção de energia em uma situação normalizada no patamar da potência nominal da planta FV de Petrolina com as perdas catalogadas no software PVsyst, onde apresenta uma média anual de 4,47 kWh/kWp/dia. É possível observar que essa produção energética é bastante afetada

pelos meses de inverno, onde há uma queda de mais de 40% na produção de energia, se comparados os meses de janeiro e junho e também observado em Campos (2015).

Figura 35 - Performance Ratio (PR) da Usina CRESA, em Petrolina.



Fonte: PVsyst, (2024) Adaptado pelo autor.

A International Electrotechnical Commission (IEC), organização internacional de padronização de tecnologias elétricas, eletrônicas e relacionadas, por meio da norma IEC 61724-1, estabelece o padrão para monitoramento de sistemas fotovoltaicos. A análise, da Performance Ratio (Figura 35), é feita pela relação entre a performance específica do sistema com a performance específica de referência.

Consoante com SMA Solar Technology (2018), Performance Ratio (PR) é a taxa de desempenho de um sistema fotovoltaico independentemente da localização e, muitas vezes descrito como um fator de qualidade. Esta relação de desempenho é expressa em porcentagem e descreve a relação entre os resultados energéticos reais e teóricos do sistema fotovoltaico. O resultado mostra a proporção de energia disponível para injetar na rede após dedução da perda de energia por aquecimento dos módulos fotovoltaicos ou por queda de tensão nos condutores. Naturalmente, quanto mais próximo de 100% estiver o valor da PR estipulada para um sistema fotovoltaico, mais eficaz é este sistema. Em geral, sistemas fotovoltaicos eficientes atingem, contudo, uma Performance Ratio de até 80%. Desta forma, mostra a proporção de energia que está realmente disponível para a rede após descontadas as perdas (por exemplo, perdas térmicas e elétricas) e a energia consumida na operação da própria usina. Um número mais próximo possível de 100% indica que a usina está funcionando de forma eficiente. O valor de 100% não pode ser alcançado, tendo em vista que perdas inevitáveis sempre ocorrem durante a operação de qualquer sistema

fotovoltaico. No entanto, usinas de alta performance podem alcançar valores de até 80%. No caso da Usina CRESP, se PR médio anual ficou em 77,3%.

As estimativas do PVsyst em Petrolina apresentaram um MAPE com valor de 18,75% representando o erro em relação aos valores reais e um desvio padrão de 28,04 kWh para energia estimada e 14,53 kWh para energia medida.

Tabela 25 - Coef. Correlação e métricas de Erro do modelo PVsyst para Petrolina.

Coeficiente	Resultado	
Coeficiente de Correlação	0,93047	
Erro médio Absoluto - MAE	23,4302 kWh	
Erro Médio Absoluto porcentagem - MAPE	18,752%	
Erro Quadrático Médio - MSE	860,667 kWh	
Raiz do Erro Quadrático Médio - RMSE	29,337 kWh	
Nível de Significância (alfa)	0,05	referência 95%
Intervalo de Confiança	82,18% (ESTIM.)	90,76% (MED.)

Fonte: Elaborado pelo Autor, (2024).

Os resultados do PVsyst, pelas observações nos dados e tabelas da seção 4.3.1, atingiram um erro de 7,1% do valor estimado em relação ao medido, com referência em MWh/m²/ano, Tabela 26. Uma correlação de classificação positiva e muito alta de 0,93 entre os valores analisados, Tabela 25.

Tabela 26 – Métricas Estatísticas Petrolina PVsyst.

	kWh/m² Estimado	kWh/m² Medido
Média	3399,78	3192,43
Desvio Padrão	28,04154	14,53340
Variância	786,3282	211,2197
Coeficiente de Variação	20,1%	21%
Mediana	3534,42	3295,79
Valor Mínimo	1216,69	1096,52
Primeiro Quartil	2886,84	2728,32
Segundo Quartil	3534,42	3295,79
Terceiro Quartil	4249,62	3788,27
Valor Máximo	5389,71	5126,34
Soma (Mwh/m ² /ano)	4087	3796,64

Fonte: Elaborado pelo Autor, (2024).

Quando se compara a produção por kWh/m², o erro médio percentual entre os valores ficou na faixa de 10,57% salvando as devidas proporções e correspondências,

mostrado na Tabela 44 mais adiante, média da geral que registrou o valor de 3399,78 para a radiação estimada e 3192,43 para a radiação medida em kWh/m², Tabela 26.

4.3.2 Dados Gerais - Planta FV Messias II

Tabela 27 - Balanços e resultados principais Messias II.

Ano	GHI kWh/m ²	DHI kWh/m ²	T_Amb °C	GHI Inc kWh/m ²	GHI Efe. kWh/m ²	E Efet. MWh	E_Inj. MWh	PR
Janeiro	188,4	78,69	26,30	194,6	187,9	133,3	130,4	0,775
Fevereiro	166,2	79,69	26,59	167,7	161,8	115,5	113,1	0,781
Março	187,8	81,52	26,85	183,0	176,2	126,2	111,1	0,702
Abril	158,6	70,04	25,81	148,9	142,6	103,9	101,9	0,792
Maio	139,9	68,25	24,91	126,9	120,6	89,8	88,1	0,803
Junho	123,4	54,22	23,59	110,0	104,4	78,3	69,9	0,736
Julho	129,1	58,84	23,24	116,1	110,1	82,7	81,1	0,808
Agosto	150,7	75,55	23,34	140,1	133,7	99,7	97,8	0,808
Setembro	162,9	70,77	23,76	156,3	150,1	109,9	107,7	0,797
Outubro	182,5	71,42	25,01	182,2	175,7	125,7	123,0	0,781
Novembro	196,6	67,52	25,62	203,0	195,8	138,8	130,1	0,742
Dezembro	195,7	82,57	26,41	204,1	197,1	139,8	136,8	0,776
Anual	1981,7	859,09	25,11	1933	1856	1343,6	1290,9	0,773

Fonte: PVsyst - Adaptado (2024)

Legenda:

GHI - Irradiação horizontal total.

T_Amb - Temperatura ambiente.

DHI - Irradiação difusa horizontal.

E EF - Energia efetiva à saída.

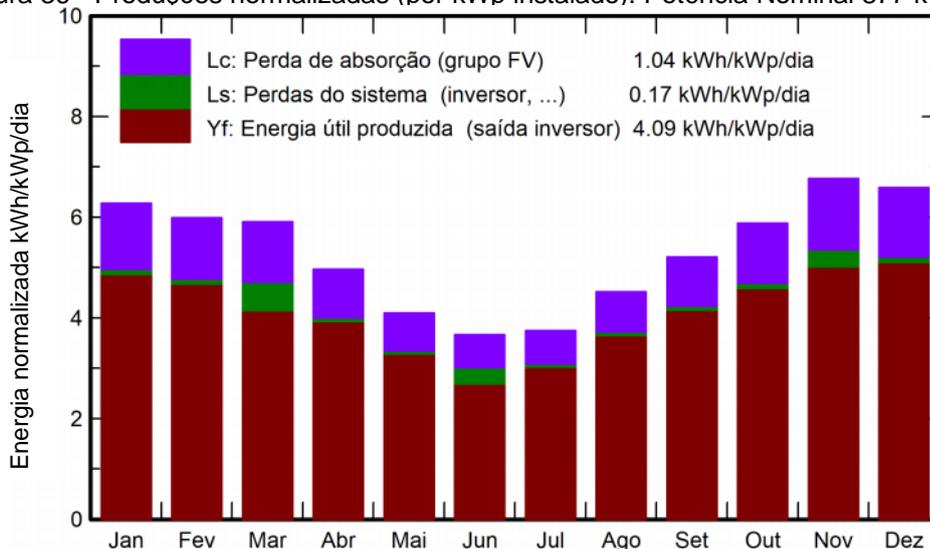
E_INJ - Energia injetada na rede.

PR - Índice de performance.

GHI EF - Global efetivo, p/ IAM e sombras.

GHI Inc – Ghi incidente.

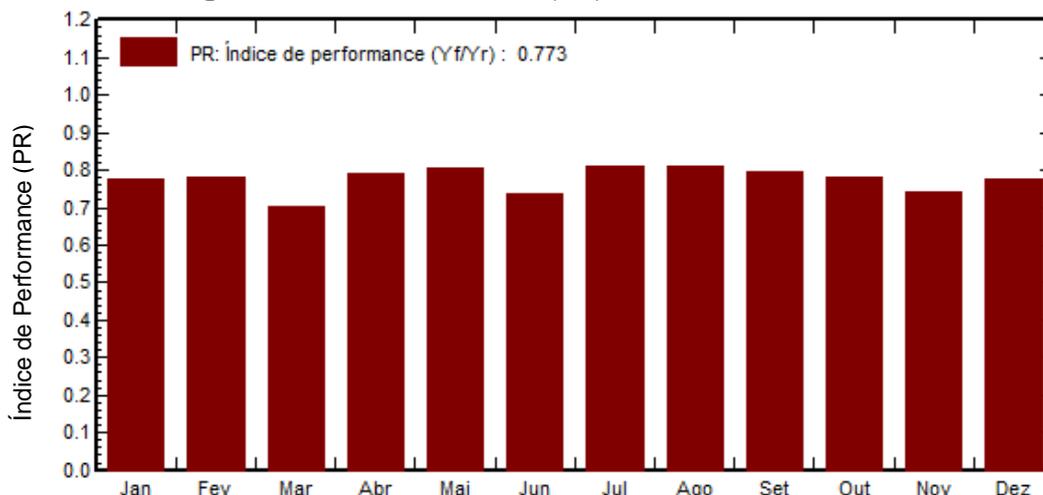
Figura 36 - Produções normalizadas (por kWp instalado): Potência Nominal 877 kWp.



Fonte: PVSYST, (2024) Adaptado pelo autor.

O gráfico da Figura 36 retrata a produção de energia em uma situação normalizada no patamar da potência nominal da planta FV de Messias com as perdas catalogadas no software PVsyst, onde apresenta uma média anual de 4,09 kWh/dia. É possível observar que essa produção energética é muito afetada nos meses de inverno, reduzindo mais de 40% a produção energética, seguindo o mesmo comportamento apresentado na planta FV de Petrolina.

Figura 37 - Performance Ratio (PR) da Usina, em Messias



Fonte: PVSYST (2024) Adaptado pelo autor.

Para o gráfico da Figura 37, aplica-se as mesmas observações da seção 4.3.2, O Performance Ratio médio em Messias sofreu uma variação ao longo do ano levemente maior do que o de Petrolina, atingindo 0,773 e sendo considerado de alta performance. Embora se observa que o PR em ambas as localidades são valores iguais, pode-se observar nos Gráficos PR (Figuras 35 e 37) assim como nas (Tabelas 24 e 27) que se tratam de valores diferentes. Ocorreu por parte do software PVsyst um arredondamento.

As estimativas obtidas com o PVsyst em Messias alcançaram um MAE de 9,53 kWh e um MAPE de 9,57%, representando o erro em relação aos valores reais e um desvio padrão de 20,85 kWh para radiação estimada e 23,31 kWh para a radiação medida, para mais ou para menos. Conforme dados observados nas tabelas da seção 4.3.2.

O coeficiente de Correlação de Pearson apresentou uma marca de 0,85, caracterizando uma alta correlação positiva entre o kWh/m² estimado e o medido, conforme Tabela 28, de acordo com a tabela 14 onde descreve a interpretação dos coeficientes de correlação de Pearson de acordo com o valor do índice e um intervalo de confiança entre os valores que representa 86,74% para os valores de produção energética estimada e 92,13% para produção energética medida.

Tabela 28 - Coef. Correlação e métricas de Erro do modelo PVsyst para Messias.

Coeficiente	Resultado	
Coeficiente de Correlação	0,85351	
Erro Médio Absoluto - MAE	9,5321 kWh	
Erro Médio Absoluto porcentagem - MAPE	9,57%	
Erro Quadrático Médio - MSE	138,145 kWh	
Raiz do Erro Quadrático Médio - RMSE	11,754 kWh	
Nível de Significância (alfa)	0,05	referência 95%
Intervalo de Confiança	86,74% (ESTIM)	92,13% (MED.)

Fonte: Elaborado pelo Autor, (2024).

Tabela 29 – Métricas Estatísticas Petrolina PVsyst Messias II em (kWh/m²).

	kWh/m² Estimado	kWh/m² Medido
Média	3107,583	3210,24
Desvio Padrão	20,869	12,376
Variância	435,519	153,186
Coeficiente de Variação	19,39%	12,67%
Mediana	3442,21	3295,79
Valor Mínimo	1180,04	1096,52
Primeiro Quartil	2933,45	2728,32
Segundo Quartil	3552,22	3295,79
Terceiro Quartil	3889,33	3788,27
Valor Máximo	5564,32	5126,34
Soma (Mwh/m ² /ano)	1291	1171,74

Fonte: Elaborado pelo Autor, (2024).

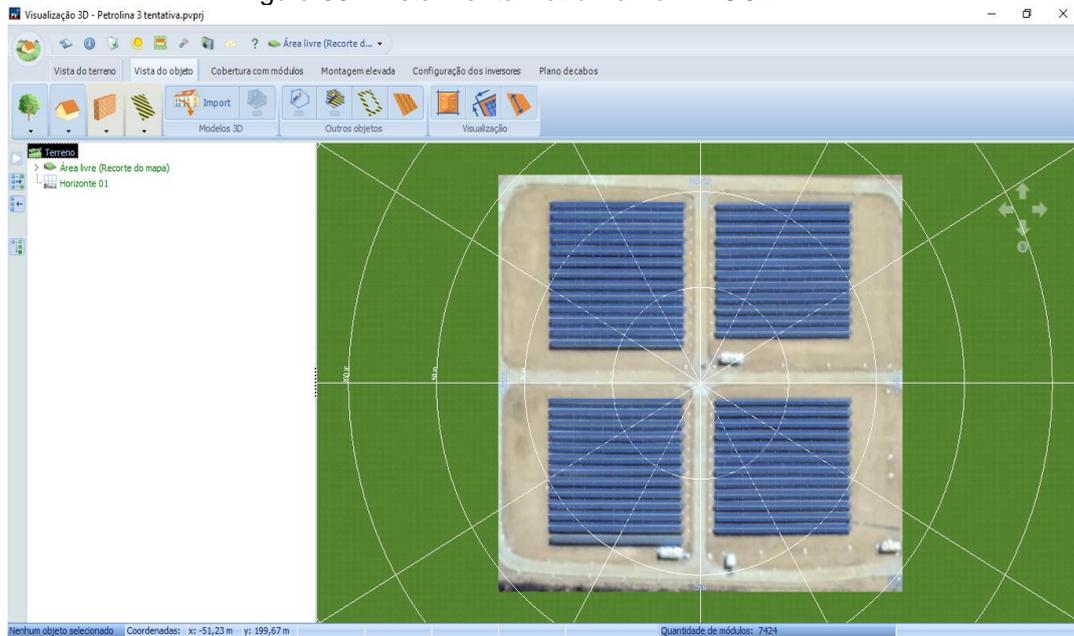
4.4 Resultados Obtidos com o Software PV*SOL

Um dos pontos fortes verificados durante os testes do software PVSOL foi a sua representação gráfica, a ligação com a geolocalização da planta e a visualização do terreno e possíveis obstáculos que possam causar sombreamento sobre os módu-

los, conforme visto na Figura 38. Ajustes e observações por parte dos usuários do software, quando bem utilizados geram maior fidedignidade nos resultados.

4.4.1 Dados Gerais – Planta FV CRESP Petrolina

Figura 38 - Vista Planta Petrolina no PV*SOL.



Fonte: PV*SOL, (2024) Adaptado pelo autor.

Na Tabela 30 estão os dados estimados pelo PV*SOL de energia mensal gerada, totalizando anualmente aproximadamente 4007 MWh, enquanto a energia gerada medida na planta em todo ano de 2023 foi de aproximadamente 3796 MWh, o que dá uma diferença percentual de 5,5%. A produção estimada pelo software seguiu o padrão de queda nos meses de inverno e correspondeu aos comportamentos de nebulosidade e variação de radiação nesses respectivos meses.

Tabela 30 - Energia Mensal Estimada via PV*SOL para a Planta FV de Petrolina

Energia do Estimada Planta FV CRESP Petrolina						
Mês	Jan	Fev	Mar	Abr	Mai	Jun
MWh	399,22	345,83	340,04	288,69	255,14	235,12
Mês	Jul	Ago	Set	Out	Nov	Dez
MWh	255,06	315,01	363,66	411,28	397,43	401,24

Fonte: PV*SOL, (2024) Adaptado pelo autor.

E a produção estimada pelo software, seguiu o padrão de queda nos meses de inverno e correspondeu aos comportamentos de nebulosidade e variação de radiação nesses respectivos meses.

Tabela 31 – Coef. Correlação e métricas de Erro do PV*SOL para Petrolina.

Coeficiente	Resultado	
Coeficiente de Correlação	0,85804	
Erro médio Absoluto - MAE	20,2801 kWh	
Erro Médio Absoluto porcentagem - MAPE	21,76%	
Erro Quadrático Médio - MSE	590,625 kWh	
Raiz do Erro Quadrático Médio - RMSE	24,303 kWh	
Nível de Significância (alfa)	0,05	referência 95%
Intervalo de Confiança	88,62% (ESTIM.)	89,16% (MED.)

Fonte: Elaborado pelo Autor, (2024).

Tabela 32 – Métricas Estatísticas Petrolina PV*SOL.

	kWh/m² Estimado	kWh/m² Medido
Média	4257,803	4147,436
Desvio Padrão	23,4604	20,8691
Variância	99,3446	211,2186
Coeficiente de Variação	18,08%	19,39%
Mediana	4461,8	4300,32
Valor Mínimo	970,81	1225
Primeiro Quartil	3950,79	3640,71
Segundo Quartil	4461,76	4291,75
Terceiro Quartil	4838,632	4852,822
Valor Máximo	5467,07	5722,33
Soma (Mwh/m ² /ano)	4007	3797

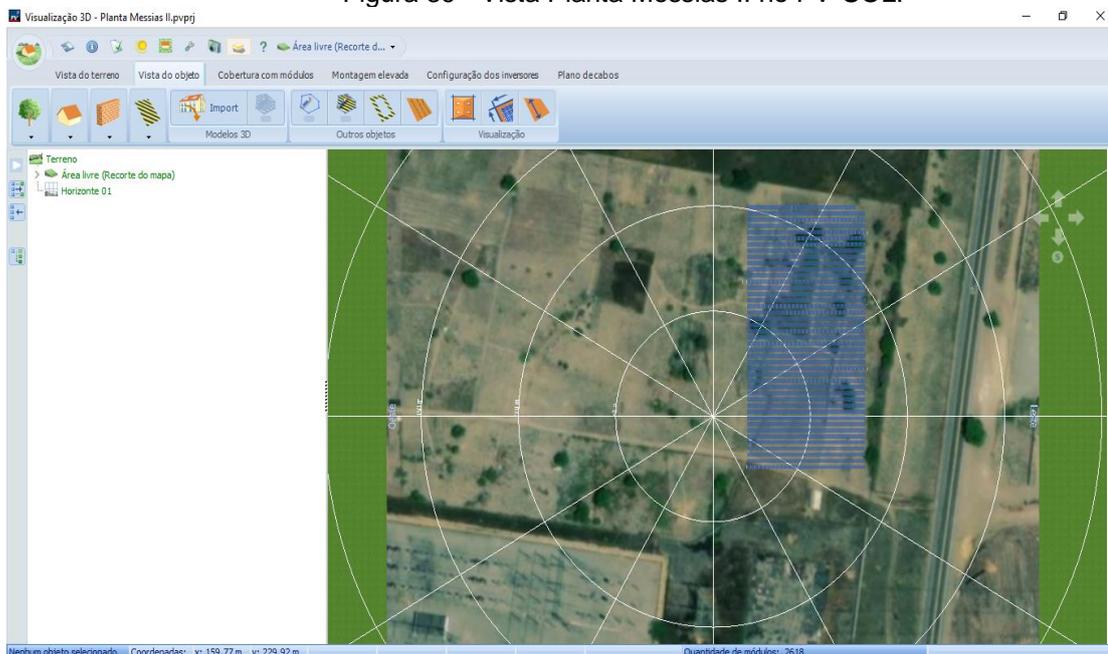
Fonte: Elaborado pelo Autor, (2024).

A correlação entre os dados de produção de energia medidos e estimados pelo PV*SOL de 0,85. O Erro médio absoluto MAPE para valores mensais atingiu um patamar de 21,76% e um MAE de 20,2 kWh, considerados altos. Os desvios-padrões de energia estimada e medida apresentaram valores de 23,46 kWh/m² e de 20,86 kWh/m², respectivamente, o que indica que as duas séries possuem variância semelhante. Corroborando com isso, a variação entre os quartis apontou uma diferença não muito considerável entre as duas séries.

4.4.2 Dados Gerais - Planta FV Messias II

A figura 39 traz uma foto via satélite do local da usina indicado no PV*SOL, onde é possível visualizar detalhes da disposição das placas.

Figura 39 - Vista Planta Messias II no PV*SOL.



Fonte: PV*SOL, (2024) Adaptado pelo autor.

As estimativas de energia gerada pela planta FV realizadas pelo PV*SOL podem ser conferidas na Tabela 33 e obtiveram um valor acumulado anual de 1378 MWh/ano. A energia gerada medida na planta em todo ano de 2023 foi de apenas 118,19 MWh, devido à redução na produção energética por fatores operacionais e de manutenção, embora a capacidade de produção prevista em projeto gire em torno de 1.474 MWh anuais, o que não está muito longe dos valores estimados. A produção estimada pelo software, seguiu o padrão de queda nos meses de inverno e correspondeu aos comportamentos de nebulosidade e variação de radiação nesses respectivos.

Tabela 33 - Energia Mensal Estimada via PV*SOL para a Planta FV de Messias II

Energia do Estimada Planta Fotovoltaica Messias II						
Mês	Jan	Fev	Mar	Abr	Mai	Jun
MWh	133,56	127,24	119,9	104,64	88,95	81,41
Mês	Jul	Ago	Set	Out	Nov	Dez
MWh	88,54	103,08	116,6	123,52	121,47	134,12

Fonte: PV*SOL, (2024) Adaptado pelo autor.

Tabela 34 - Métricas Estatísticas Messias II PV*SOL.

	kWh/m² Estimado	kWh/m² Medido
Média	3752,4700	3203,9609
Desvio Padrão	18,1985	12,3768
Variância	331,1866	153,1865
Coeficiente de Variação	27,96%	22,41%
Mediana	3800,26	3296,59
Valor Mínimo	1010,24	1096,52
Primeiro Quartil	3101,76	2729,78
Segundo Quartil	3800,26	3296,59
Terceiro Quartil	4628,01	3788,49
Valor Máximo	5480,47	5126,34
Soma (Mwh/m ² /ano)	1378,1	1028

Fonte: PV*SOL, (2024) Adaptado pelo autor.

A Correlação das saídas de energia gerada do PV*SOL em Messias seguiu a tendência das outras apresentadas nesse estudo, apresentando um valor de 0,81. O erro médio absoluto ficou na casa dos 15,09 e com erro médio absoluto percentual na faixa dos 15,39 %, Tabela 35, enquanto que no PVSYST o valor obtido consta como 9,57 %, Tabela 28.

Tabela 35 - Coef. Correlação e métricas de Erro do PV*SOL para Messias

Coeficiente	Resultado	
Coeficiente de Correlação	0,8122	
Erro médio Absoluto - MAE	15,09 kWh	
Erro Médio Absoluto porcentagem - MAPE	15,39 %	
Erro Quadrático Médio - MSE	312,504 kWh	
Raiz do Erro Quadrático Médio - RMSE	17,678 kWh	
Nível de Significância (alfa)	0,05	referência 95%
Intervalo de Confiança	88,43%(ESTIM.)	92,13% (MED.)

Fonte: PV*SOL, (2024) Adaptado pelo autor.

Na Tabela 34 podem ser observados um desvio padrão entre os valores estimados e medidos de respectivamente 18,19 kWh/m² e 12,37 kWh/m², indicando uma diferença considerável nas variâncias das duas séries. Este fato também pode ser evidenciado se olharmos para as diferenças entres os quartis das duas séries. Constatou-se ainda dados de produção energética de 1028 MWh/m²/ano para a energia

medida (desconsiderando a área que ficou inoperante e completando os dados faltantes), 1378 MWh/m²/ano para a estimada e 1474 MWh/m²/ano para a calculada em projeto.

4.5 Resultados Obtidos com o Software Neural Designer

4.5.1 Dados Gerais – Planta FV CRESP Petrolina

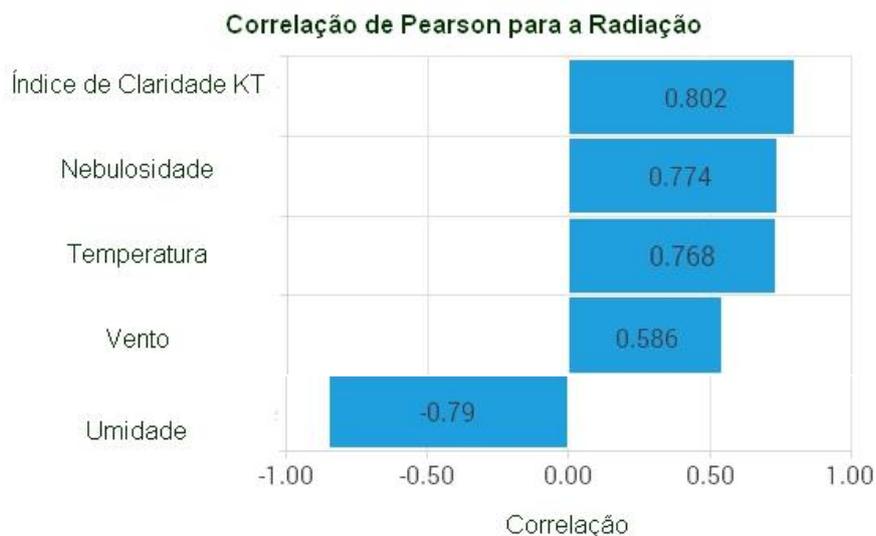
Tabela 36 - Dados Gerais Neural Designer Planta Petrolina.

	Índice	Mínimo	Máximo	Média	Desvio
Precipitação (mm)	1	0	111,2	0,571	6,29
Temp. Módulo	2	20	44	27	2,55
Umidade Relativa (%)	3	61,3	93,2	79,4	7,6
Vel. Vento (m/s)	4	5,61	15,7	9,54	1,67
Temperatura °C	5	21,8	30,9	26,4	1,73
Índice de Claridade KT	6	0,21	0,8	0,622	0,118
Radiação (kWh)	8	2.33e+03	6.50e+03	3.34e+03	866

Fonte: Neural Designer, (2024) Adaptado pelo autor.

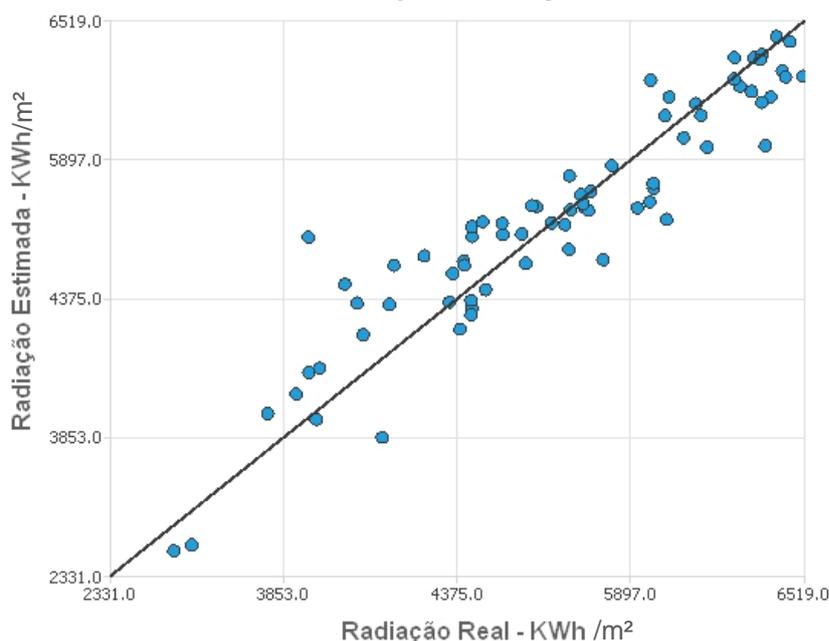
Nebulosidade por se tratar de uma constante de estados, não foi computada na Tabela 36 acima, pois variam de “status” como: Nublado, parcialmente nublado, parcialmente claro e céu claro.

Figura 40 - Correlação Radiação x Entradas em Petrolina



Fonte: Neural Designer, (2024) Adaptado pelo autor.

Figura 41 – Radiação Estimada x Medida - Bondade do Ajuste CRESP Petrolina.
Bondade do Ajuste - Radiação KWh/m²



Fonte: Neural Designer, (2024) Adaptado pelo autor.

A tabela 37 a seguir, lista os parâmetros de adequação para a saída Radiação referentes a correlação entre as variáveis estudadas.

Tabela 37 - Coef. Correlação e métricas de Erro do N. Designer CRESP Petrolina.

	Resultado	
Coeficiente de Correlação	0,7854932	
Erro médio Absoluto - MAE	16,66 kWh	
Erro Médio Absoluto porcentagem - MAPE	13,42%	
Erro Quadrático Médio - MSE	445,342 kWh	
Raiz do Erro Quadrático Médio - RMSE	21,103 kWh	
Nível de Significância (alfa)	0,05	referência 95%
Intervalo de Confiança	94,33%(EST.)	89,17%(MED.)

Fonte: Neural Designer, (2024) Adaptado pelo autor.

Alta correlação positiva apresentou o Neural Designer nos seus testes, sendo mais uma mostra de que os três softwares analisados, acrescidos do método determinístico de potência de saída de uma FV apresentaram correlações positivas, fortes e próximas.

Tabela 38 - Tabela de Erros de Teste CRES P Petrolina

Erros do Teste de Dados	Mínimo	Máximo	Médio	Desvio
Erro Absoluto	2,811	1970,36	386,584	332,146
Erro Relativo	0,004617	0,323647	0,06349	0,05455
Porcentagem de erro	0,0461734	32,36	6,35	5,46

Fonte: Neural Designer 2024

A tabela 38 acima, mostra os mínimos, máximos, médias e desvios padrão dos erros absolutos e percentuais da rede neural para os dados de teste.

Tabela 39 - Erros do modelo para CRES P Petrolina.

	Treinamento	Seleção	Teste
Erro de soma quadrada	5567,37	5000,9	4311,96
Erro quadrático médio	25,42	68,51	59,89
Raiz do Erro quadrático médio	5,02	8,28	7,74
Erro quadrático normalizado	0,079	0,165	0,133

Fonte: Neural Designer, (2024) Adaptado pelo autor.

Esta tarefa mede todos os erros do modelo, considera cada amostra utilizada e avalia o modelo para cada uso, separando os resultados de erro para cada etapa existente nas redes neurais e está apresentado na Tabela 39.

4.5.2 Dados Gerais - Planta FV Messias II

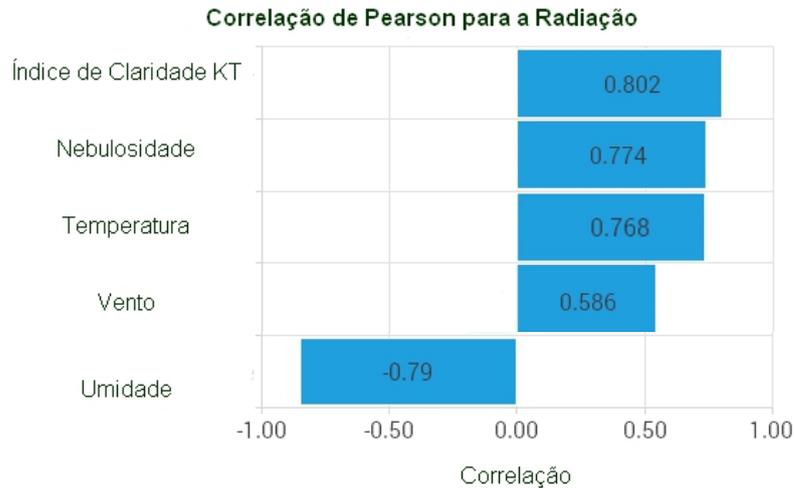
Tabela 40 - Dados Gerais Neural Designer Planta Messias II.

	Índice	Mínimo	Máximo	Média	Desvio
Precipitação (mm)	1	0	188.6	0.218	5.944
Temp. Módulo	2	21	48	28,3	4,78
Umidade Relativa (%)	3	40	100	77,9	13,2
Vel. Vento (m/s)	4	0,1	9,8	3,08	1,4
Temperatura °C	5	19,7	33,8	26,8	2,51
Índice de Claridade KT	6	0,166	0,715	0,528	0,114
Radiação (kWh)	8	1,15e+03	6,60e+03	3,45e+03	918

Fonte: Neural Designer, (2024) Adaptado pelo autor.

Nebulosidade por se tratar de uma constante de estados, não é computada na Tabela 40 acima, pois variam de “status” como: Nublado, Parcialmente Nublado, Parcialmente Claro e Céu Claro.

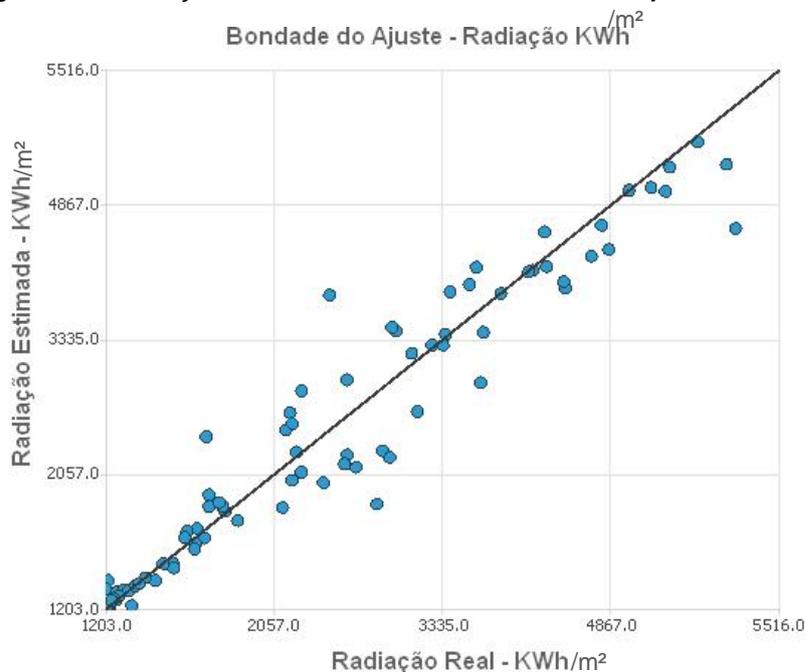
Figura 42 - Correlação Radiação x Entradas em Messias II



Fonte: Neural Designer, (2024) Adaptado pelo autor.

No gráfico de correlação da Figura 42, demonstra a força dos seguintes itens nos testes: Índice de Claridade KT, nebulosidade, temperatura e umidade.

Figura 43 - Radiação Estimada x Medida - Bondade do Ajuste Messias II.



Fonte: Neural Designer, (2024) Adaptado pelo autor.

A tabela 41 a seguir lista os parâmetros de adequação para a saída Radiação. O coeficiente de Correlação mede a intensidade e a direção de relações lineares. A

intensidade diz respeito ao grau de relacionamento entre duas variáveis. Quanto mais próximo dos extremos do intervalo, (-1 e +1) mais forte é a correlação.

Tabela 41 - Coef. Correlação e métricas de Erro do N. Designer Messias II.

		Resultado
Coeficiente de Correlação		0,8965135
Erro médio Absoluto - MAE		23,494 kWh
Erro Médio Absoluto porcentagem - MAPE		23,76 %
Erro Quadrático Médio - MSE		643,06 kWh
Raiz do Erro Quadrático Médio - RMSE		25,25 kWh
Nível de Significância (alfa)	0,05	referência 95%
Intervalo de Confiança	91,77%(EST.)	92,13%(MED.)

Fonte: Neural Designer, (2024) Adaptado pelo autor.

Tabela 42 - Tabela de Erros de Teste Messias II.

Erros do Teste de Dados	Mínimo	Máximo	Médio	Desvio
Erro Absoluto	0,004531	379,89	60,34	58,62
Erro Relativo	3,95e-06	0,3315	0,05266	0,0511
Porcentagem de erro	0,000395	33,15	5,266	5,115

Fonte: Neural Designer, (2024) Adaptado pelo autor.

A Tabela 42 acima, mostra os mínimos, máximos, médias e desvios padrão dos erros absolutos e percentuais da rede neural para os dados de teste. Vale frisar a porcentagem de erro médio no valor de 5,266%. Uma porcentagem baixa em relação a demanda de dados analisada, um ponto positivo a se observar no estudo.

Tabela 43 - Erros do modelo para Messias II.

	Treinamento	Seleção	Teste
Erro de soma quadrada	4375,67	2496,19	2398,31
Erro quadrático médio	1,793	3,07	2,95
Raiz do Erro quadrático médio	1,339	1,752	1,718
Erro quadrático normalizado	0,088	0,087	0,081

Fonte: Neural Designer, (2024) Adaptado pelo autor.

4.6 Produção energética nos Softwares, Saída de Potência e Estudos Similares

4.6.1 Planta Fotovoltaica CRESP Petrolina (PE)

A tabela 43 traz uma comparação dos valores medidos de energia produzida pela Planta FV com valores estimados pelo modelo determinístico da planta (coluna "Estimada"), pelo PVSyst, pelo PV*SOL e pelo Neural Design (Coluna "Neural").

Tabela 44 - Resultados da Energia Produzida no modelo determinístico e nos Softwares e suas Porcentagens para Petrolina.

	KWH ESTIMADA	KWH MEDIDA	% ERRO ESTIMADA/MEDIDA	KWH PVSYST	KWH PV*SOL	KWH NEURAL DESIGNER	% ERRO PVSYST	% ERRO PV*SOL	% ERRO NEURAL DESIGNER
Jan	127,15	127,02	0,10	181,58	160,71	165,22	42,95	26,52	30,07
Fev	126,68	117,11	8,18	138,64	138,80	131,29	18,38	18,52	12,11
Mar	116,05	119,26	-2,70	162,80	135,44	134,91	36,51	13,57	13,12
Abr	109,13	125,40	-12,98	137,16	114,43	108,87	9,38	-8,75	-13,19
Mai	92,01	106,24	-13,40	104,67	100,90	111,31	-1,48	-5,02	4,77
Jun	94,13	102,87	-8,49	94,18	92,73	108,12	-8,44	-9,85	5,11
Jul	120,95	138,51	-12,67	103,15	99,27	121,93	-25,53	-28,33	-11,97
Ago	131,04	138,42	-5,33	123,48	124,74	144,45	-10,79	-9,88	4,36
Set	145,51	141,72	2,67	145,49	144,91	149,25	2,66	2,25	5,31
Out	153,65	152,26	0,91	157,89	164,36	153,34	3,70	7,95	0,71
Nov	143,21	122,05	17,34	167,90	159,40	161,71	37,57	30,60	32,50
Dez	142,47	122,97	15,86	156,94	160,81	157,18	27,62	30,77	27,82
Anual	1501,98	1513,82	-0,78	1673,88	1596,51	1647,59	10,57	5,46	8,84

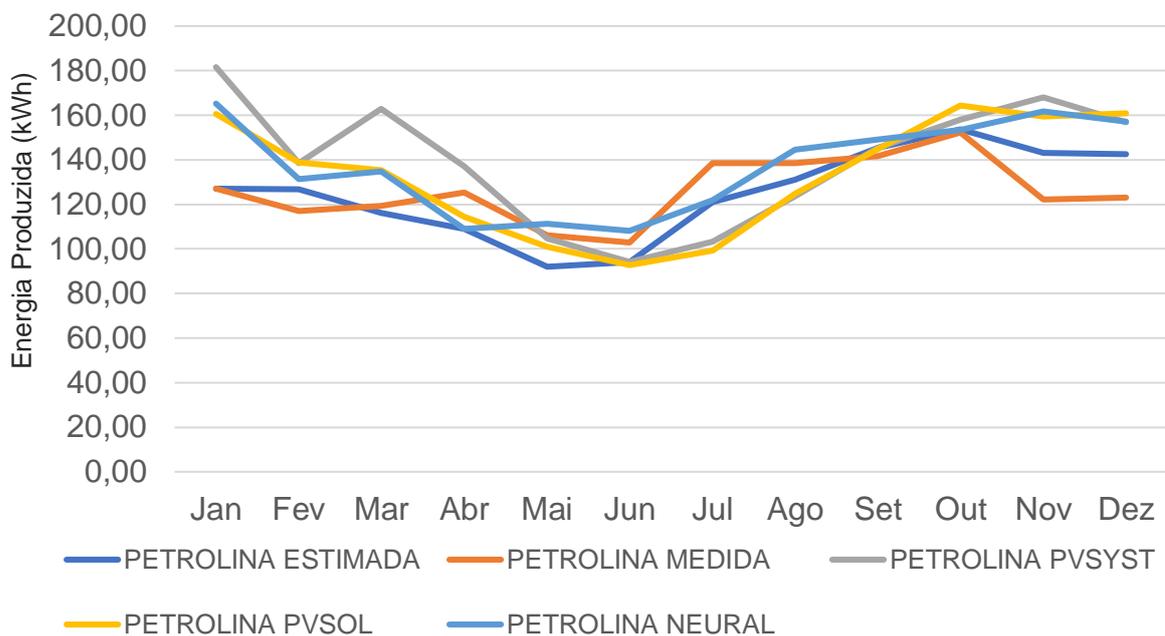
Fonte: Elaborado pelo Autor, (2024).

Dos Santos e De Lima (2022) apresentaram uma linha de pesquisa em que o comparativo, segundo os testes dos autores, entre a energia medida e estimada pelo PVSyst foi computada em 7%, enquanto nos cálculos deste estudo o valor registrado em Petrolina foi 10,57% e para valores da planta FV Messias o presente estudo apresentou o valor de 10,18%.

Observando os erros percentuais do PVSyst apresentados nas Tabelas 44 e 45, os quais tem como referência os valores medidos, tais erros atingiram o valor médio de 10,57% para a planta FV de Petrolina e de 10,18% para a planta FV de Mes-

sias. A título de comparação, Machado et al. (2020) analisaram o erro percentual entre energia medida e estimada via PVsyst e constataram valores de erros percentuais variando entre -10,71% e +6,07%. Por outro lado, os valores estimados pelo do PV*SOL neste trabalho atingiram erros percentuais médios de 5,46% para a planta FV de Petrolina e de 17,61% para Messias, enquanto que os erros encontrados no trabalho de Machado et al. (2020) variaram entre -12,75% e +4,29%.

Figura 44 - Gráfico da Energia nos Softwares na Planta Petrolina em (kWh).



Fonte: Elaborado pelo Autor, (2024).

Foram analisados ainda os valores de PR obtidos pelo PVsyst para Petrolina e Messias, os quais obtiveram valores idênticos, na faixa de 0,773. Em seu trabalho, Umar et al. (2018) também chegaram a essa convergência entre PR's para uma usina situada em Noida - Índia, obtendo valores médios de 0,799 para o PVsyst e 0,805 para o PV*SOL.

Um estudo similar dirigido por Barros (2022), apresentou uma pesquisa utilizando o PV*SOL E PVsyst para a cidade de Colônia Leopoldina, no estado de Alagoas, onde teve como resultados uma porcentagem de 3,10% de diferença entre energia medida e estimada pelo PVsyst e 0,06% para o PV*SOL; e no presente estudo na Planta FV de Petrolina 10,57% PVsyst e 5,46% PV*SOL, enquanto o mesmo estudo apresentou 10,18% PVsyst e 17,61% PV*SOL para a planta FV de Messias.

4.6.2 Planta Fotovoltaica Messias II (AL)

Na tabela 45 é apresentada uma síntese das comparações entre os valores de energia gerada medida em Messias e os valores estimados pelo modelo determinístico da planta (coluna "kWh Estimada"), pelo PVSyst, pelo PV*SOL e pelo Neural Design (Coluna "kWh Neural Designer").

Tabela 45 - Resultados da Energia Produzida no modelo determinístico e nos Softwares e suas Porcentagens para Messias II.

	KWH ESTIMADA	KWH MEDIDA	% ERRO ESTIMADA/MEDIDA	KWH PVSYST	KWH PV*SOL	KWH NEURAL DESIGNER	% ERRO PVSYST	% ERRO PV*SOL	% ERRO NEURAL DESIGNER
Jan	132,84	111,65	18,98	130,40	136,47	151,38	16,79	22,23	35,58
Fev	114,73	95,96	19,56	113,10	125,10	130,31	17,86	30,37	35,80
Mar	121,97	109,10	11,80	111,10	121,59	139,15	1,83	11,45	27,54
Abr	102,57	95,93	6,92	101,90	102,14	117,04	6,22	6,47	22,01
Mai	92,13	92,71	-0,63	88,10	90,08	105,13	-4,97	-2,84	13,40
Jun	76,22	75,07	1,53	69,90	81,70	86,97	-6,89	8,83	15,85
Jul	85,18	89,69	-5,03	81,10	85,32	97,18	-9,58	-4,87	8,35
Ago	98,30	88,91	10,56	97,80	103,43	112,16	10,00	16,33	26,15
Set	101,81	89,34	13,96	107,70	116,17	115,99	20,55	30,03	29,83
Out	119,85	101,21	18,42	123,00	133,82	135,53	21,53	32,22	33,91
Nov	104,48	100,23	4,24	130,10	141,03	119,45	29,80	40,71	19,18
Dez	125,86	121,94	3,21	136,80	141,21	143,38	12,19	15,80	17,58
Anual	1275,94	1171,74	8,89	1291,00	1378,07	1453,69	10,18	17,61	24,06

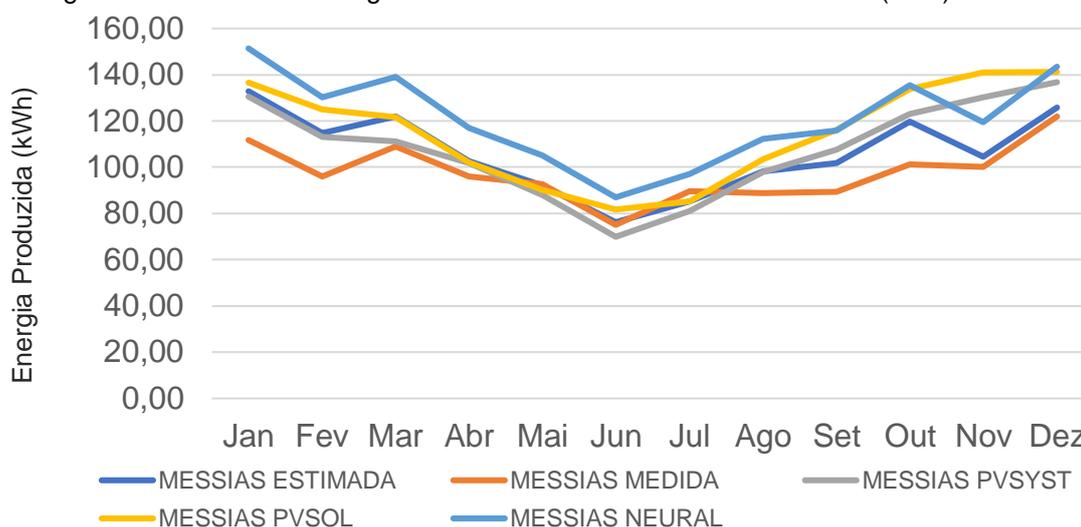
Fonte: Elaborado pelo Autor, (2024).

Por conseguinte, o valor de 8,89% de diferença anual entre a produção energética da planta FV estimada versus a medida, utilizando os cálculos de potência de saída já mencionados no estudo e incorporando as perdas também citadas no presente estudo e esperadas no sistema FV, na Tabela 45.

Observando as Tabelas 44 e 45, percebe-se que os erros cometidos pelos modelos foram, de forma geral, maiores em Messias do que em Petrolina. Na Planta FV de Petrolina, os erros foram de 10,57% para o PVSyst e 5,46% para o PV*SOL, enquanto que, para Messias, esses erros foram de 10,18% para o PVSyst e 17,61% para o PV*SOL. Este fato pode estar relacionado com a maior nebulosidade média em Messias (42%) do que em Petrolina (39%), conforme pode ser comparado nas Tabelas 17 e 21.

Médias mensais da energia medida e as produzidas pelos modelos determinístico (aqui chamada de Estimada), PVsyst, PV*SOL e NEURAL DESIGNER em Messias, Tabela 45 e na Figura 45.

Figura 45 - Gráfico da Energia nos Softwares na Planta Messias II em (kWh).



Fonte: Elaborado pelo autor (2024).

Em relação aos estudos referentes ao Neural Designer, se destaca o uso na planta geração de energia solar instalada em Berkeley, no estado da Califórnia (EUA), por Constantin e López (2023), com um erro médio percentual de 6,04% e correlação com valor de 0,95.

Segundo Ranganathan. et al. (2021) reforça o uso do software em seus estudos e suas vantagens. Enquanto no presente estudo o erro médio utilizando o mesmo software apresentou valores de percentual de 6,35% para Petrolina, enquanto a correlação para Petrolina apresentou valor de 0,78 e 6,35% de erro médio percentual, para Messias uma correlação média de 0,89 e erro médio percentual de 5,26%. Apesar de um desempenho um pouco abaixo com relação aos softwares comerciais mais utilizados, o Neural Design tem acurácia razoável de suas estimativas, o torna uma solução a ser considerada em projetos de pesquisa que disponham de poucos recursos financeiros.

Em relação à correlação de Pearson, Petrolina apresentou valores que vão desde 0,77 a 0,93 e Messias apresentou valores de 0,81 a 0,89. Um estudo similar foi dirigido por Medeiros (2023), onde o mesmo produziu uma análise de modelos utilizados na estimativa da geração de energia de uma usina fotovoltaica localizada em Petrolina, onde a correlação de Pearson variou de 0,69 a 0,94. O mesmo estudo apontou um erro médio absoluto MAPE de 14%, enquanto o presente estudo apresenta valores de MAPE de

7,97% a 18,75% para resultados dos softwares analisados e com o software Neural Designer, os valores de MAPE para a planta FV de Petrolina apresentou 13,42% e a para a planta FV de Messias o valor de MAPE de 23,76%. Na comparação entre os estudos, o presente estudo conseguiu valores médios de 0,773 de Performance Ratio, enquanto no estudo proposto por Medeiros, o valor variou de 0,76 a 0,88.

Do mesmo modo, estudos foram conduzidos na literatura sobre a investigação do desempenho de sistemas fotovoltaicos já instalados, por meio da utilização de programas computacionais. Nesse sentido, Rocha (2019) comparou a produção de energia gerada por um sistema fotovoltaico em Rio Negro com os valores de energia simulados pelo software PVSyst, e encontrou uma diferença de 2,2% entre a energia simulada e a energia real produzida pelo sistema. Enquanto nos cálculos deste estudo o valor registrado em Petrolina foi 10,57% e para valores da planta FV Messias o presente estudo apresentou o valor de 10,18%.

Já Ströher (2020) analisou o desempenho de um sistema fotovoltaico de 62,1 kWp em um estudo de caso na cidade de Garibaldi-RS. Os resultados obtidos pelo software PV*SOL e os medidos e calculados por meio dos dados do sistema de monitoramento dos inversores constataram variação de, aproximadamente, 4,5% nos dez meses de operação. Enquanto nos cálculos deste estudo o valor registrado em Petrolina foi 5,46% e para valores da planta FV Messias o presente estudo apresentou o valor de 17,61%.

E para finalizar, segundo estudos de Ramos (2022), voltados também para a planta FV CRESP – Petrolina, o melhor resultado da simulação de stringbox mostrou uma diferença de 46,3 kWh em relação à geração real e a prevista, com uma MAE de 19,41 kWh (Presente estudo MAE 23,43 kWh) e uma RMSE de 36,38 kWh (Presente estudo RMSE 29,33 kWh, cuja parametrização foi utilizada para simular a planta FV completa e avaliar seu desempenho. Para auxiliar numa maior compreensão dos estudos apontados no presente estudo, a Tabela 46 a seguir, demonstra as principais características e semelhanças entre os estudos similares utilizados e o presente estudo.

4.6.3 Quadro Comparativo Indicadores Estatísticos

Algumas métricas estatísticas do Software Neural Designer estão na Tabela 46, para conferência e para observarmos a proximidade desses mesmos valores assim como também auxiliar nas etapas de análise dos estudos similares apresentados.

Tabela 46 - Erros de métricas estatísticas geradas utilizando o Neural Designer

Método	Localidade	Correlação	MAE (kWh)	MAPE	MSE (kWh)	RMSE (kWh)
Método Determinístico	Petrolina	0,7794	868,22	7,97 %	107,847	10,385
	Messias	0,89274	498,81	8,44 %	138,145	11,754
PVsyst	Petrolina	0,93047	23,430	18,75%	860,667	29,337
	Messias	0,85351	9,532	9,57%	138,145	11,754
PV*SOL	Petrolina	0,85804	20,280	21,76%	590,625	24,303
	Messias	0,8122	15,09	15,39%	312,504	17,678
Neural Designer	Petrolina	0,78549	16,66	13,42%	445,342	21,103
	Messias	0,89651	23,494	23,76%	643,06	25,25

Fonte: Elaborado pelo autor (2024).

Mais adiante na Tabela 47, está demonstrado um quadro onde foi realizado um resumo dos estudos similares analisados e as similaridades com o presente estudo, foi detalhado os autores e ano de produção do estudo, localidades analisadas, entradas e as respectivas fontes de software utilizadas e os métodos estatísticos e matemáticos utilizados como resultado para análise.

4.6.4 Quadro Comparativo entre os Estudos Similares Analisados e o Presente Estudo

Tabela 47 - Quadro de comparação dos estudos

Autores	Entradas	Localidade	PVSYST	PV*SOL	Neural Designer	Outros Softwares	MAE	RMSE	MAPE	Perform. Ratio	% Estimada/ Medida (Kwh)
Barros (2022)	GHI, Temp. e dados climáticos	C.Leopoldina AL	X	X			X				
Medeiros (2023)	GHI e DNI	Petrolina PE					X	X		X	
Ranganathan et al. (2021)	Dados Técnicos	Uttar Índia			X	X					
Rocha (2019)	Geração (KWh)	Rio Negro PR	X								X
Constantin e López (2024)	GHI, Temp. e dados climáticos	Berkeley CA			X		X	X	X	X	X
Dos Santos e De Lima (2022)	GHI, Temp. e dados climáticos	Uberlândia MG	X								X
Machado (2020)	GHI, Temp., dados climáticos e de Geração	Campinas SP	X	X			X				
Ramos	GHI, Temp. e dados climáticos	Petrolina PE	X				X	X	X		X
Umar et al. (2018)	GHI, Temp. e dados climáticos	Noida Índia	X	X		X					
Ströher (2020)	GHI, Temp. e dados climáticos	Garibaldi RS		X							X
Presente Estudo (2023-2024)	GHI, Temp., dados climáticos e de Geração	Petrolina PE Messias AL	X	X	X		X	X	X	X	X

Fonte: Elaborado pelo Autor, (2024).

5 CONCLUSÕES

Durante a pesquisa, a maior dificuldade apresentada foi a aquisição de dados completos, coesos e que possuíssem qualidade. Tal dificuldade foi contornada após a consulta de várias fontes, separando as mais confiáveis e completas, mesmo que estas fontes estivessem a uma certa distância do ponto em estudo. De posse dos dados, partiu-se para a etapa da qualificação, filtragem dos dados e período analisado. Infelizmente nessa fase, as maiores dificuldades foram a falta de padrão, falta de dados e a quantidade de estações, que, mesmo operacionais, possuem lacunas ou não fornecem todos os dados necessários. Apesar de possuímos uma rede de estações espalhadas por todo Brasil, ainda se verificam lacunas em algumas regiões.

Foram analisadas duas localidades no Nordeste com peculiaridades bem visíveis quanto ao clima. Messias (AL), pela proximidade com o litoral, tem maiores índices de precipitação (944 mm), chegando a ser quase o dobro da média da outra localidade, Petrolina (PE), com médias de 430 mm. Quanto a temperatura média anual, há uma similaridade entre as duas cidades observadas, Messias e Petrolina, com uma média anual de 25,16°C. O índice de nebulosidade em Messias (AL), se manteve na faixa de 42%, tendo Petrolina índice menor que gira em torno de 39%. No quesito umidade, Messias (AL), com 76%, enquanto Petrolina (PE) com 58%.

Quanto à questão da irradiação, foram observados valores maiores na Planta Petrolina (PE) girando em torno de uma média anual de 5,76 kWh, enquanto Messias (AL) 5,22 kWh. Tal característica refletiu numa maior produção energética em Petrolina (PE), onde, de acordo com os dados e testes, foram observados valores entre 1501 a 1673 kWh/m²/ano, enquanto que Messias (AL) apresentou uma faixa de 1171 a 1453 kWh/m²/ano.

No presente trabalho foi aberta uma breve discussão para expor os fatores de perdas das plantas FV e influência de corpos d'água próximos a estações meteorológicas, com o intuito de criar uma perspectiva sobre a possibilidade da mudança climática e de produção de energia nas proximidades desses locais onde há um acúmulo de água.

O uso do modelo determinístico de energia de saída para as plantas FV, levando em consideração as perdas esperadas para as mesmas, gerou valores subestimados, apresentaram uma diminuição de 0,78% para a planta FV de Petrolina e sobre-estima-

dos para Messias, apresentando um aumento de 8,89% em relação à medida. Quanto ao Coeficiente de Correlação de Pearson, Petrolina atingiu valores que vão desde 0,77 a 0,93 e Messias com valores de 0,81 a 0,89. Estudos similares também apresentaram correlações nessa mesma ordem de grandeza.

Quanto ao software Neural Designer, o erro médio percentual foi de 6,35% para Petrolina (PE) e em Messias (AL) com erro médio percentual de 5,22% para o presente estudo, enquanto estudos similares apresentaram erros de 6,04%.

Comparando a produção de energia gerada pelos demais softwares, os resultados apresentaram-se numa faixa de erros tolerável. Petrolina (PE) teve um desempenho de 5,46% a mais no PV*SOL em relação a produção medida, seguida de 8,84% a mais de produção energética no Neural Designer e 10,57% a mais de produção no PVSYST. Já em relação a Messias os valores são de 10,18% a mais em produção energética no PVSYST, 17,61% a mais no PV*SOL e 24,06% no Neural Designer.

Diante do presente estudo, os resultados da produção energética da planta FV apresentaram uma proximidade dos valores encontrados na literatura e de projeto das plantas, podendo servir de base para validação dos projetos futuros de energia solar da Eletrobras. Sugere-se a realização de estudos mais aprofundados e com mais fontes de dados meteorológicos, na tentativa de melhorar o desempenho dos softwares disponíveis.

A seguir, seguem algumas sugestões para trabalhos futuros:

1. Refinamento e otimização do modelo computacional com base nos resultados obtidos;
2. Implementação do modelo em outras plantas de geração fotovoltaicas para maior validação e teste em diferentes cenários, localidades e equipamentos;
3. Disseminação dos resultados e compartilhamento das melhores práticas com a comunidade acadêmica e industrial, buscando novas parcerias de estudos sobre o tema;
4. Com mais estudos utilizando os softwares analisados neste estudo, definir um software padrão para uso, como base na comparação dos resultados;
5. Disseminação para os projetistas, funcionários e gestores que lidam diretamente com plantas FV na Eletrobras.

REFERÊNCIAS

ALLEN, R.G.; PEREIRA, L.; RAES, D.; SMITH, M. **Crop evapotranspiration: guidelines for computing crop water requirements**. Rome: FAO, 1998. (FAO. Irrigation and Drainage Paper, 56)

ALMEIDA, MARCELO PINHO. **Qualificação de sistemas fotovoltaicos conectados à rede**. 2012 173f. Dissertação (Mestrado) – Universidade de São Paulo – USP, Programa de Pós-Graduação em Energia – PPGE, São Paulo.

ALVES, MARLIANA DE OLIVEIRA LAGE. **Energia solar: estudo da geração de energia elétrica através dos sistemas fotovoltaicos on-grid e off-grid** / Marliana de Oliveira Lage Alves. – 2019.

ANEEL, **Expansão da Matriz Elétrica Brasileira – maio 2023** (adaptada), Disponível em: https://www.gov.br/aneel/pt-br/assuntos/noticias/2023/novas-usinas-em-operacao-comercial-no-ano-somam-4-610-20-mw/infograficoExpansodaGeraoMaio2023.png/@_@images/81ee76ab-95e7-4150-b3f7-c843a218f1b9.png. Acesso em 20 de fevereiro de 2024.

ANTONANZAS, J., OSORIO, N., ESCOBAR, R., URRACA, R., MARTINEZ-DE-PISON, F. J., AND ANTONANZAS-TORRES, F., 2016. **Review of Photovoltaic Power Forecasting**, Solar Energy, 136, pp. 78–111.

ARAÚJO, D. N., COSTA, S. C. S., DUPONT, I. M., CARVALHO, P. C. M., 2018. **Impactos da sujidade e efeitos da limpeza no desempenho de módulos fotovoltaicos**. In: VII Congresso Brasileiro de Energia Solar-CBENS, Gramado-RS.

ATLAS SOLAR GLOBAL, **Global Solar Atlas - Map**. Disponível em: <https://globalsolaratlas.info/map?c=11.609193,8.613281,3>, Acesso em: 10 jan 2024.

BALFOUR, J., SHAW, M., & NASH, N. B. **Introdução ao projeto de sistemas fotovoltaicos**. (2016). LTC, Rio de Janeiro.

BARROS, RODRIGO ALEX SILVA. **Análise comparativa entre os softwares PVSYST e PV*SOL**. / Rodrigo, Alex Silva Barros. – 2022. 47f.: il Acesso em jan 2024.

BLASZCZAK, VINÍCIUS. **Análise de Eficiência de Painel Fotovoltaico com Sistema Tracker Seguidor Solar**. UFFS. Erechim.; 2017. Disponível em: <https://rd.uffs.edu.br/bitstream/prefix/1695/1/BLASZCZAK.pdf>. Acesso em: fev. 2021.

BRAGA, A. P., CARVALHO, A. P. DE L., LUDERMIR T. B., 2007. **Redes Neurais Artificiais: Teoria e Aplicações**. 2ª edição, Editora LTC, Rio de Janeiro.

BRAGA, PEREIRA RENATA. **Energia solar fotovoltaica: fundamentos e aplicações**. 2019. TCC (Graduação) - Graduação, Rio de Janeiro, 2019.

BRUCE, Peter; BRUCE, Andrew. **Estatística prática para cientistas de dados: 50 conceitos essenciais**. 1ª edição. Rio de Janeiro — RJ: Alta Books, 2019.

C.W. KUO, T.M. KUAN, W.L. CHUEH, L.G. WU, C.C. HUANG, C.Y. YU, in **7th World Conf. Photovolt. Energy Convers.**, IEEE (2018) 1029

CABRAL, C. V. T. **Análise de dimensionamento estocástico e determinístico de sistemas fotovoltaicos isolados** (2006)., Tese de Doutorado, Universidade Federal de Viçosa, Minas Gerais.

CAMARGO, F. A. C. *et al.* **The influence of meteorological parameters in the generation of energy in photovoltaic panels: A case study of Smart Campus Facens**, SP, Brazil. *Urbe*, v. 11, p. 1–15, 2019

CAMPOS, HENRIQUE MARIN VAN DE BROOKE. **Geração Distribuída de Energia Solar Fotovoltaica na Matriz Elétrica de Curitiba e Região: Um Estudo de Caso**, Dissertação (Mestrado em Engenharia Civil) Programa de Pós-Graduação em Engenharia Civil, (UTFPR), Curitiba, 2015;

CANADIAN SOLAR INC. **PV Module Product Datasheet V5.552_EN. MaxPower (1500 V) CS6U-325|330|335P**, 1 dez. 2017.

CARNEIRO, T. C., DE CARVALHO, P. C. M., ALVES DOS SANTOS, H., LIMA, M. A. F. B., BRAGA, A. P. D. S., 2021. **Review on Photovoltaic Power and Solar Resource Forecasting: Current Status and Trends**. *Journal of Solar Energy Engineering*, 144(1), 010801 2022. <https://doi.org/10.1115/1.4051652>.

CARNEIRO, T. C., SANTOS, H. A. D., BRAGA, A. P. D. S., & CARVALHO, P. C. M. D. 2014. **Redes neurais artificiais para previsão de velocidade do vento: estudo de caso para Maracanaú–CE**. Congresso Brasileiro de Automática.

CASSINI, D. A., OLIVEIRA, M. C.C., SOARES. L.G., VIANA, M.M., LINS, V. F. C., DINIZ. A.S. A.C., ZILLES. R., KARMERSKI, L.L. **Avaliação experimental do desempenho da degradação de módulos fotovoltaicos de Si cristalino após 15 anos de exposição em campo**. In: VIII Congresso Brasileiro de Energia Solar - CBENS, Gramado. 2018.

CHERIF, H.; BELHADJ, J. **Methodology for accurate energy production estimation of photovoltaic power generation station**. *Electrotechnical Conference (MELECON)*, 2012 16th IEEE Mediterranean. IEEE, 2012. p. 561-566

Chuchvaga, N. et al., 2023. **Development of Hetero-Junction Silicon Solar Cells with Intrinsic Thin Layer: A Review**. *Coatings* 13, 796. Acesso em: 23 julho 2024.

CLIMA TODAY, **Dados históricos climáticos das maiores cidades do mundo**. Disponível em: <https://clima.today/BR/>, Acesso em: 10 jan 2024.

CONSTANTIN, A, LÓPEZ, R. **Predict the generation of a solar plant using machine learning**. Disponível em: <https://www.neuraldesigner.com/learning/examples/solar-power-generation/> Acesso em: 01 fev 2024.

COSTA, T. M. G. **Metodologia para projeto de microgeração fotovoltaica, Dissertação de Mestrado**, (2015). Universidade Federal de Minas Gerais, B. H.

CRESESB. **Potencial Solar - SunData v3.0** Disponível em: <http://www.cresesb.cepel.br/index.php#data> Acesso em: 10 de janeiro de 2024.

CRESP. **Centro de Referência em Energia Solar de Petrolina** Disponível em: <https://www.chesf.com.br/pdi/Documents/Centro%20de%20Refer%C3%Aancia%20em%20Energia%20Solar%20de%20Petrolina.pdf> Acesso em: 22 setembro de 2024.

DOS SANTOS, LEONARDO NERY CARRIJO; DE LIMA, GERSON FLÁVIO MENDES. **Dimensionamento prático de um sistema fotovoltaico—estudo de caso utilizando o software** Brazilian Journal of Development, v. 8, n. 3, p. 20035-20047, 2022.

DUFFIE, J., BECKMAN, W. **Solar engineering of thermal processes**. Fourth Edition. Wiley. 2013

DUFFIE, JOHN; BECKMAN, WILLIAM. **Solar engineering of thermal processes**. 2 Ed. New York: John Wiley & Sons, 1991.

E 4.0 ENERGIAS RENOVAVEIS, **Potência maior de módulos que a potência do inversor, pode?** 21 out 2022. Disponível em:

<https://www.e4energiasrenovaveis.com.br/artigos/posso-instalar-potencia-maior-de-modulos-que-a-potencia-do-inversor>, Acesso em: 10 jan 2024.

ENERGYINST. **Statistical Review of World Energy 2023**. Disponível em: <https://www.energyinst.org/statistical-review>. Acessado em 20 de fevereiro de 2024.

EPE. **Balço Energético Nacional 2023**. 23 jan. 2023. Disponível em:

https://www.epe.gov.br/sites-pt/publicacoes-dadosabertos/publicacoes/PublicacoesArquivos/publicacao-748/topico-681/BEN_S%C3%ADntese_2023_PT.pdf. Acesso em: 23 fev. 2024.

ESCOBEDO, J. F., TERAMOTO, E. T., OLIVEIRA, A. P., SOARES, J., & CODATO, G. (2012). **Equações de estimativa das frações solar direta (K_{Dh}) e difusa (K_d) em função do índice de claridade (K_t) e razão de insolação (n/N)**. Avances en y Medio Ambiente, 16.

FAN, J., WU, L., ZHANG, F., CAI, H., ZENG, W., WANG, X., & ZOU, H. **Empirical and machine learning models for predicting daily global solar radiation from sunshine duration: A review and case study in China**. *Renewable and Sustainable Energy Reviews*, (2019). 100, 186-212.

FREIRE SERGIO MIRANDA. Livro Eletrônico: **Bioestatística Básica**. Rio de Janeiro, Projeto: Desenvolvimento de Material Didático para o Ensino de Estatística. LAMPADA – Laboratório Médico de Pesquisas Médicas Avançadas – UERJ, 2020. Disponível : http://www.lampada.uerj.br/arquivosdb/_book/bioestatisticaBasica.html

GALLEGO, C.; COSTA, A.; CUERVA, Á.; LANDBERG, L.; GREAVES, B.; COLLINS, J.A **Wavelet-based Approach for Large Wind Power Ramp Characterisation**. *Wind Energy*. v. 16, n. 2, p. 257-278, 2013.

GOOGLE. **Google Earth** website. <http://earth.google.com/>, 2024.

GUEDES, D.; TORRES, B. **Células fotovoltaicas: desenvolvimento e as três gerações**. Revista Técnico-Científica do CREA-PR, mar. 2019.

GURGEL, J. T. A., FREDERICO PIMENTEL GOMES, AND A. P. TRIVELIN. **“Determinação da média aritmética e desvio padrão de quocientes de séries independentes e dependentes.”** Anais da Escola Superior de Agricultura Luiz de Queiroz 14 (1958): 31-42.

HAYKIN, SIMON S, **Redes Neurais: Princípios e Prática** (Bookman Companhia Editora, Porto Alegre, 2001), 2ª ed., 900 p.

HAYKIN, SIMON S. **Neural networks: a comprehensive foundation**. ed. New York: Macmillan, 1999

HEINRICH, M., MEUNIER, S., SAMÉ, A., QUÉVAL, L., DARGA, A., OUKHELLOU, L., MULTON, B., 2020. **Detection of cleaning interventions on photovoltaic modules with machine learning**. Applied Energy, Elsevier, Vol.263, p. 114642.

HONGYU, Du; XUEJUN, Song; HONG, Jiang; ZENGHUI, Kan; ZHIBAO, Wang; YONGLI, Cai. **Research on the cooling island effects of water body: a case study of Shanghai, China**. Ecological Indicators 67 (2016) 31-38

INMAN, R. H.; PEDRO, H. T. C.; COIMBRA, C. F. M. **Solar forecasting methods for renewable energy integration**. Progress in Energy and Combustion Science. v. 39, n. 6, p.535-576, 2013.

INMET, **Instituto Nacional de Meteorologia - Mapa de Estações Meteorológicas**. Disponível em: <https://portal.inmet.gov.br/servicos/mapa-de-esta%C3%A7%C3%B5es-meteorol%C3%B3gicas> , Acesso em: 10 jan 2024.

INPE, **Instituto Nacional de Pesquisas Espaciais** Disponível em: <https://www.gov.br/inpe/pt-br>, Acesso em: 10 jan 2024.

INSTITUTO SOLAR, **Dimensionamento de Sistemas Solares**, 20 jun 2020. Disponível em: <https://institutosolar.com/dimensionamento-de-sistemas-fotovoltaicos/> Acesso em: 10 jan 2024

IEA-PVPS, **Soiling Losses – Impact on the Performance of Photovoltaic Power Plants 2022**, disponível em : <https://iea-pvps.org/wp-content/uploads/2023/01/IEA-PVPS-T13-21-2022-REPORT-Soiling-Losses-PV-Plants.pdf> Acesso em : 23 mar 2024.

JAMIL, B., & SIDDIQUI, A. T. **Generalized models for estimation of diffuse solar radiation based on clearness index and sunshine duration in India: applicability under different climatic zones**. Journal of Atmospheric and SolarTerrestrial Physics (2017)., 157, 16-34.

KITAYAMA, M., NARVAEZ, D. I., MELO, K. B., COSTA, T. S., SIQUEIRA, T. G. & VILLALVA, M. G. **Comparative analysis of meteorological databases and transposition models applied to photovoltaic systems**. 2018. Proceedings XXII Congresso Brasileiro de Automática. <https://doi.org/10.20906/cps/cba2018-0672>.

KYMAKIS, E.; KALYKAKIS, S.; PAPAZOGLU, T. **Performance analysis of a gridconnected photovoltaic park on the island of Crete**. Energy Conversion and Management, v. 50, p. 433 – 438, 2009. Acesso em: 04 de outubro de 2024.

LABMET, **Laboratório de Meteorologia – Universidade Vale do São Francisco**. Disponível em: <http://labmet.univasf.edu.br/>, Acesso: 10 jan 2024.

LABREN, **Laboratório de Modelagem e Estudos de Recursos Renováveis de Energia** Disponível em: <https://labren.ccst.inpe.br/> Acesso em: 22 set 2024.

LI W., LING Y., LIU X., HAO Y. **Performance analysis of a photovoltaic-thermochemical hybrid system prototype**. Applied Energy 204: 939-947, 2017.

- LIMA, M. A. F. B., CARVALHO, P. C. M., FERNÁNDEZ-RAMÍREZ, L. M., AND BRAGA, A. P. S., 2020. **Improving Solar Forecasting Using Deep Learning and Portfolio Theory Integration**, Energy, 195, p. 117016.
- LUIZ, A., LIRA, O., AZEVEDO, S.D., & EMILIAVACA, S. **Avaliação Da Degradação De Módulos Fotovoltaicos Policristalinos Na Cidade De Natal Após 4 Anos De Exposição Ao Ar Livre**. (2022). *Anais Congresso Brasileiro de Energia Solar - CBENS*.
- MACEDO, MARLOS; RESENDE, FELIPE; MARINHO, MANOEL. (2020). **Utilização de Células Orgânicas Poliméricas na Geração de Energia Elétrica**. 10.48011/asba.v2i1.1415. Acesso em: 10 setembro de 2024.
- MACHADO, C. T.; MIRANDA, F.S. **Energia Solar Fotovoltaica: uma breve revisão**. REV. Virtual Quim, 2015, 7(1), 126-143. Acesso em: 19 jan 2024.
- MACHADO, Felipe Nery Rodrigues. **Big data: o futuro dos dados e aplicações**. São Paulo: Érica, 2018.
- MACHADO, G. M. V *et al*, 2020. **Estudo de caso de um sistema fotovoltaico instalado no campus da Unicamp em diferentes softwares de simulação**, Anais, VIII Congresso Brasileiro de Energia Solar.
- MAGARREIRO, CLARISSE; FREITAS, Sara; BRITO, Miguel. C. **Radiação e energia solar**. Faculdade de Ciências Universidade de Lisboa. Art. geral, Vol 39.
- MAGHAMI, M. R., HIZAM, H., GOMES, C., RADZI, M. A., REZADAD, M. I., HAJIGHORBANI, S., 2016. **Power loss due to soiling on solar panel: A review**. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 59, p. 1307-1316.
- MAIA, LILIANA ANDREIA GUIMARÃES. **Estudo Comparativo de Produção entre Centrais Fotovoltaicas de Silício Policristalino e Amorfo**. 94 f. Dissertação Curso de Mestrado em Energias Sustentáveis, Departamento de Engenharia Mecânica, Instituto Superior de Engenharia do Porto, Portugal, 2016. Disponível em: https://recipp.ipp.pt/bitstream/10400.22/10407/1/DM_LilianaMaia_2016_MES.pdf. Acesso em: 25 nov. 2023.
- MANTEGHI, GOLNOOSH; LIMIT, HASANUDDIN BIN; REMAZ, DILSHAN. **Water Bodies an Urban Microclimate: A review** Modern Applied Science. V.9, nº 6, 2015.
- MARQUES, I. C. A. & DELVIZIO, E. S. (2020). **Estudo de viabilidade técnica de microgeração residencial fotovoltaica**. Revista Científica Multidisciplinar Núcleo do Conhecimento. Ano 05, Ed. 05, 03, 166-203.
- MASIERO, ERICO. **Análise da influência de corpos d'água em microclimas urbanos: estudo de caso em São José do Rio Preto**, SP. 2014. 143 fls. Tese (Doutorado em Engenharia Urbana), Universidade Federal de São Carlos, 2014.
- MEDEIROS, JOÃO VICTOR FURTADO FRAZÃO DE. **Avaliação de modelos utilizados na estimativa da geração de energia de uma usina fotovoltaica localizada no semiárido brasileiro**. 2023. Dissertação (Mestrado em Tecnologias Energéticas e Nucleares) – Universidade Federal de Pernambuco, Recife, 2023.
- MELO, K., TAVARES, L. R. & VILLALVA, M. G. (2021). **Statistical Analysis of Solar Position Calculation Algorithms: SPA and Grena**, pp. 1-5. IEEE Latin America Transactions. <https://doi.org/10.1109/TLA.2021.9461843>.

- MERTYAGLI, G., YANG, D., AND SRINIVASAN, D., 2019. **Automatic Hourly Solar Forecasting Using Machine Learning Models**. Renewable Sustainable Energy Rev., 105, pp. 487–498.
- MUKAKA, M. M. 2012. **Statistics Corner: A Guide to Appropriate Use of Correlation Coefficient in Medical Research**. Malawi Medical Journal: The Journal of Medical Association of Malawi, 24, pag. 69-71
- MURAT ATES, A.; SINGH, H. **Rooftop solar Photovoltaic (PV) plant – One year measured performance and simulations**. Journal of King Saud University - Science, v. 33, n. 3, p. 101361, 2021.
- NASCIMENTO, CÁSSIO ARAÚJO DO. **Princípio de funcionamento da célula fotovoltaica**. 21 f. Monografia (Especialização) - Curso de Fontes Alternativas de Energia, Dpt de Eng., Universidade Federal de Lavras, Lavras, 2004. Disponível em: <https://www.docsity.com/pt/celulas-fotovoltaicas/4710003/> Acesso: 25 de nov. 2023.
- NASCIMENTO, L.M.A, FERREIRA, R. A. F. **Otimização de um sistema fotovoltaico conectado à rede elétrica: considerações sobre a eficiência do sistema e análise de posicionamento**. Revista de Engenharia e Tecnologia.v.10, Nº 3. Dez/2018.
- NEURAL DESIGNER, Neural Network and Machine Learning Software Disponível em: <https://www.neuraldesigner.com/> Acesso em: 15 nov. 2023.
- OAKENERGIA. **Sistema fotovoltaico e seus fundamentos**.2021 Disponível em: <https://oakenergia.com.br/sistema-fotovoltaico-guia-completo-energia-solar/> Acesso em: 17 de janeiro de 2024.
- OKONKWO, G. N., & NWOKOYE, A. O. C. **Estimating global solar radiation from temperature data in Minna location**. 2014 European Scientific Journal, 10(15).
- OLIVEIRA, L. G. M., 2017. **Avaliação de fatores que influenciam na estimativa da geração e operação de sistemas fotovoltaicos conectados à rede elétrica**, Tese Doutorado, Universidade Federal de Minas Gerais, Belo Horizonte.
- ONS. **Energia Agora Carga E Geração**. Disponível em: <https://www.ons.org.br/paginas/energia-agora/carga-e-geracao>. Acesso: 22 fev.2024.
- ONS. **Resultados da Operação**. Disponível em: <https://www.ons.org.br/Paginas/resultados-da-operacao/boletim-geracao-solar.aspx> Acesso: 22 out.2024.
- OPUS SOLAR, **Como surgiu a energia solar?** Disponível em: <https://opussolar.com.br/wp-content/uploads/2-1110x425.png>. Acesso: 20 fev.2024
- PEREIRA, E. B.; MARTINS, F. R.; GONÇALVES, A. R.; COSTA, R. S.; LIMA, F. J. L.; RÜTHER, R.; ABREU, S. L. de; TIEPOLO, G. M.; PEREIRA, S. V.; SOUZA, J. G. de. **Atlas brasileiro de energia solar**. 2a. ed. São José dos Campos: INPE, 2017. Disponível em:http://labren.ccst.inpe.br/atlas_2017.html. Acesso 14 jan. 2024.
- PEREIRA, F.; OLIVEIRA, M. **Curso técnico instalador de energia solar fotovoltaica**.Porto: Publindústria, 2011.

PEREIRA, LUCAS. **Memorial Descritivo da Usina Fotovoltaica Chesf – Petrolina PE WEG** Recife: Chesf, 2022. p. 17.

PINHO, J. T.; GALDINO, M. A. **Manual de Engenharia para Sistemas Fotovoltaicos**. Rio de Janeiro: CEPEL - CRESESB, 2014.

PORTAL SOLAR. **Energia Solar no Mundo**. Disponível em: <https://www.portalsolar.com.br/energia-solar-no-mundo>. Acesso em: 17 jan. 2024.

PV*SOL, **PV*SOL Valentim Software**, 2023. Disponível em: https://valentin-software.com/en/products/PV*SOL-premium/. Acesso em: 15 nov. 2023

PVsyst, **Photovoltaic Software features**, 2023. Disponível em: <https://www.pvsyst.com/features/>. Acesso em: 15 nov. 2023.

RANGANATHAN, INDRAKUMARI & POONGODI, T. & SINGH, KIRAN. **Introduction to Deep Learning**. (2021). 10.1007/978-3-030-66519-7_1. Acesso em: 10 Set. 2024.

RAMOS, C., et al. **Cadeia de valor da energia solar fotovoltaica no Brasil**. Brasília:SEBRAE, 2018. 362p.

RAMOS, M. DA R., MEDEIROS, J. V. F. F. DE, MIRANDA, D., VILELA, O. C., PEREIRA, A. C., JATOBA, E. B., CODECEIRA NETO, A., & MELO FILHO, J. B. DE. (2022). **Avaliação De Desempenho Da Planta Fotovoltaica De 2,5 Mwp Do Cresp Com Parametrização Do Software Pvsyst**. Anais Congresso Brasileiro De Energia Solar - CBENS, 1–9. <https://doi.org/10.59627/cbens.2022.1082>

RAPHAEL, E., SILVA, M. N., SZOSTAK, R., SCHIAVON, M. A., & NOGUEIRA, A. F. (2018). **Células solares de perovskitas: uma nova tecnologia emergente**. *Química Nova*, 41(1), 61–74. <https://doi.org/10.21577/0100-4042.2017012>
REDE SONDA, **Sistema de Organização Nacional de Dados Ambientais**. Disponível em: <https://sonda.ccst.inpe.br/>, Acesso em: 10 jan 2024.

RESENDE DEGS, MANOEL. **Implantação de Sistema de Geração Fotovoltaica 700 kW Subestação de Messias II**. Recife: Chesf, 2021. 45 p.
RIBSOL. **Tipos de sistemas fotovoltaicos**. Disponível em: <https://ribsol.com.br/sistemas-fotovoltaicos/>. Acesso em: 17 de janeiro de 2024.

ROCHA, B.F.A. **Análise da produção de energia gerada de um sistema fotovoltaico em Rio Negro em comparação com os valores de energia simulados pelo software PVSyst**. Monografia (Especialização em Energias Renováveis) – Universidade Tecnológica Federal do Paraná, Curitiba, 2019.

ROSA, V. B., 2014. **Aplicação Computacional para o Dimensionamento de Sistemas Fotovoltaicos Isolados**, Trabalho de Conclusão do Curso, Escola Politécnica da Universidade Federal do Rio de Janeiro, Rio de Janeiro.

SALES, B. F., DIAS, T. J. **Influência das condições meteorológicas na geração fotovoltaica - Estudo de caso CERIn**. 2015. TCC (Bach. em Engenharia Elétrica) - Instituto de Sistemas Elétricos e Energia, Universidade Fed. de Itajubá, 2015.

SAMPAIO, J.A., AMADO, R.S., MARQUES, P.S.G, SOARES, L.G.L. **Silício Grau Solar - Uma Revisão das Tecnologias de Produção. CETEM - Centro de Tecnologia Mineral.** Série Rochas e Minerais Industriais, n. 26, Rio de Janeiro, 2019. Disponível em: <https://bityli.com/V27vm>. Acesso em: 20 ago. 2020

SCOLAR, J.; MARTINS, D.; ESCOBEDO, J. F. **Estimativa da irradiação total sobre uma superfície inclinada a partir da irradiação global na horizontal.** Revista Brasileira de Geofísica, v.21, n.3, p.249-258, 2003. Disponível em: <http://www.scielo.br/pdf/rbg/v21n3/a04v21n3.pdf>. Acesso: 13 nov. 2023.

SILVA, A. M, MELO, F.C, FREITAS, L.C.G, SOUZA, A.C, FARIAS, V.J. **Estudo dos métodos de avaliação de módulos fotovoltaicos em condições reais de operação.** In: VII Congresso Brasileiro de Energia Solar-CBENS. Gramado.2018.

SILVA, I. N. d.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas.** 1. ed. São Paulo: Artliber, 2010.

SILVA, J. L. *et al*, 2020. **A Comparative Performance of PV Power Simulation Software with an Installed PV Plant**, 2020 IEEE International Conference on Industrial Technology (ICIT), São Paulo, Brasil, pp. 531-535,. Acesso : 26 nov. 2023.

SILVA, M., ROBERTS, J. J., PRADO, P. O., 2021. **Calculation of the Shading Factors for Solar Modules with MATLAB**, Energies, 3 de ago. 2021.

SILVA, RENATO MAIA. **Redes Neurais Artificiais aplicadas à Detecção de Intrusão em Redes TCP/IP.** 2005. 144 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Centro Técnico Científica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2005. Cap. 4. Disponível em: <https://www.maxwell.vrac.pucRio.br/7335/7335_5.PDF>. Acesso: 06 out. 2023.

SMA. **“Performance Ratio. Quality factor for the PV plant”**, Technical Information, SMA Solar Technology AG, 2018.

SOUZA, MARCOS & MARIANO, ZILDA & GALVANI, EMERSON. **Lagos Artificiais e Possível Influência no Clima Local e no Clima Urbano: Estudo em Presidente Epitácio (SP).** (2018). 10.22533/at.ed.18618211215. Disponível em: https://www.researchgate.net/publication/330843918_lagos_artificiais_e_possivel_influencia_no_clima_local_e_no_clima_urbano_estudo_em_presidente_epitacio_sp Acesso em: 08 setembro de 2024.

STARTPLACE, **Boxplot: Como interpretar?** 28 ago 2019. Disponível em: <https://statplace.com.br/blog/como-interpretar-um-boxplot/> Acesso: 15 fev 2024.

STRÖHER, L.M. Análise de desempenho de um sistema fotovoltaico: estudo de caso comparando ensaios experimentais e simulação computacional. Dissertação (Mestrado em Engenharia Mecânica) – Universidade de Caxias do Sul, Programa de Pós-Graduação em Engenharia Mecânica, Caxias do Sul, 2020

SUEHRCKE, H., BOWDEN, R. S., & HOLLANDS, K. G. T. (2013). **Relationship between sunshine duration and solar radiation.** Solar Energy, 92, 160-171.

TAVARES, L. R., COSTA, T. S., MELO, K. B. & VILLALVA, M. G. **Análise Estatística de Bancos de Dados de Radiação Solar e Temperatura para Aplicação em Sistema Fotovoltaico.** (2020). VIII Cong. Brasileiro de Energia Solar.

TAVARES, P. **Observação e análise da radiação solar global e fotossinteticamente ativa na região de Maceió**. 2005. Trabalho Final de Graduação. UFA.

UMAR, NAJIB & BORA, BIRINCHI & BANERJEE, CHANDAN. **Photovoltaic performance degradation due to dust accumulation**. *American Journal of Engineering Research* (2018). 8. 185-188. Acesso em : 10 de out. 2024.

VAISHAK S., BHALE P. V. **Investigation on the effect of different backsheet materials on performance characteristics of a photovoltaic/thermal (PV/T) system**. *Renew Energy* 168, 160-169. 66, 2021.

VERMA, A. AND SINGHAL, S. **Solar PV Performance Parameter and Recommendation for Optimization of Performance in Large Scale Grid Connected Solar PV Plant**. *Journal of Energy and Power Sources* (2015), 2, 40-53.

VILLALVA, M.G.; GAZOLI J.R., **Energia solar fotovoltaica: conceitos e aplicações**, 1. Ed, São Paulo: Érica, 2012.

WANG H., AN C., DUANA M., SU J. **Transient thermal analysis of multilayer pipeline with phase change material**. *Appl. Ther. Eng.* 165, 114512, 2020

WANG, G. C., RATNAM, E., HAGHI, H. V., AND KLEISSL, J., 2019. **Corrective Receding Horizon EV Charge Scheduling Using Short-Term Solar Forecasting**, *Renewable Energy*, 130, pp. 1146–1158.

ZHOU X., TIAN S., AN J., YAN D., ZHANG L., YANG J. **Modeling occupant behavior's influence on the energy efficiency of solar domestic hot water systems**. *Applied Energy* 309: 118503, 2022.

ANEXOS

1 Código Python gerado pela Rede Neural CRESP Petrolina

Your model has been exported to this python file.

You can manage it with the 'NeuralNetwork' class.

Example:

```
model = NeuralNetwork()
sample = [input_1, input_2, input_3, input_4, ...]
outputs = model.calculate_outputs(sample)
```

Inputs Names:

- 0) Dia
- 1) Precipitacao
- 2) Umidade
- 3) Vento
- 4) Temperatura
- 5) Indice_de_Claridade_KT
- 6) parcialmente_nublado
- 7) ceu_limpo
- 8) nublado

You can predict with a batch of samples using calculate_batch_output method

IMPORTANT: input batch must be <class 'numpy.ndarray'> type

Example_1:

```
model = NeuralNetwork()
input_batch = np.array([[1, 2], [4, 5]])
outputs = model.calculate_batch_output(input_batch)
```

Example_2:

```
input_batch = pd.DataFrame( {'col1': [1, 2], 'col2': [3, 4]})
outputs = model.calculate_batch_output(input_batch.values)
```

'''

```
import numpy as np
```

```
class NeuralNetwork:
```

```
    def __init__(self):
```

```

self.inputs_number = 9
self.inputs_names = ['Dia', 'Precipitacao', 'Umidade', 'Vento',
'Temperatura', 'Indice de Claridade KT', 'parcialmente nublado', 'ceu limpo',
'nublado']

def calculate_outputs(self, inputs):
    Dia = inputs[0]
    Precipitacao = inputs[1]
    Umidade = inputs[2]
    Vento = inputs[3]
    Temperatura = inputs[4]
    Indice_de_Claridade_KT = inputs[5]
    parcialmente_nublado_o = inputs[6]
    ceu_limpo = inputs[7]
    nublado_o = inputs[8]
    scaled_Dia = (Dia-15.76099968)/8.796339989
    scaled_Precipitacao = (Precipitacao-0.5576919913)/3.284120083
    scaled_Umidade = (Umidade-79.35990143)/7.585690022
    scaled_Vento = (Vento-9.535129547)/1.671659946
    scaled_Temperatura = (Temperatura-26.40119934)/1.731580019
    scaled_Indice_de_Claridade_KT = (Indice_de_Claridade_KT-
0.6221429706)/0.1175839975
    scaled_parcialmente_nublado_o =
parcialmente_nublado_o*(1+1)/(1-(0))-0*(1+1)/(1-0)-1
    scaled_ceu_limpo = ceu_limpo*(1+1)/(1-(0))-0*(1+1)/(1-0)-1
    scaled_nublado_o = nublado_o*(1+1)/(1-(0))-0*(1+1)/(1-0)-1
    perceptron_layer_1_output_0 = np.tanh( 0.260265 +
(scaled_Dia*0.144476) + (scaled_Precipitacao*-1.63322) +
(scaled_Umidade*0.0607479) + (scaled_Vento*0.112723) +
(scaled_Temperatura*-0.310276) +
(scaled_Indice_de_Claridade_KT*0.846676) +
(scaled_parcialmente_nublado_o*0.113469) + (scaled_ceu_limpo*-0.0598664) +
(scaled_nublado_o*-0.361268) )
    perceptron_layer_1_output_1 = np.tanh( 0.193882 + (scaled_Dia*-
0.138352) + (scaled_Precipitacao*1.18079) + (scaled_Umidade*-0.182465) +

```

```

(scaled_Vento*-0.289565) + (scaled_Temperatura*0.319659) +
(scaled_Indice_de_Claridade_KT*0.106745) +
(scaled_parcialmente_nublado*0.0964403) + (scaled_ceu_limpo*0.0107292) +
(scaled_nublado*-0.194776) )
        perceptron_layer_1_output_2 = np.tanh( 0.159553 +
(scaled_Dia*-0.02395) + (scaled_Precipitacao*-0.436295) + (scaled_Umidade*-
0.122326) + (scaled_Vento*-0.192095) + (scaled_Temperatura*-0.180413) +
(scaled_Indice_de_Claridade_KT*-0.436564) +
(scaled_parcialmente_nublado*0.0199938) + (scaled_ceu_limpo*-0.113231) +
(scaled_nublado*-0.181369) )
        perceptron_layer_2_output_0 = ( -0.465631 +
(perceptron_layer_1_output_0*1.02537) +
(perceptron_layer_1_output_1*1.12338) + (perceptron_layer_1_output_2*-
0.995761) )
        unscaling_layer_output_0=perceptron_layer_2_output_0*1370.52002+6
169.990234
        Radiacao = unscaling_layer_output_0
        out = [None]*1
        out[0] = Radiacao
        return out
    def calculate_batch_output(self, input_batch):
        output_batch = [None]*input_batch.shape[0]
        for i in range(input_batch.shape[0]):
            inputs = list(input_batch[i])
            output = self.calculate_outputs(inputs)
            output_batch[i] = output
        return output_batch
    def main():
        inputs = []
        Dia = #- ENTER YOUR VALUE HERE -#
        inputs.append(Dia)

        Precipitacao = #- ENTER YOUR VALUE HERE -#

```

```
inputs.append(Precipitacao)
Umidade = #- ENTER YOUR VALUE HERE -#
inputs.append(Umidade)
Vento = #- ENTER YOUR VALUE HERE -#
inputs.append(Vento)
Temperatura = #- ENTER YOUR VALUE HERE -#
inputs.append(Temperatura)
Indice_de_Claridade_KT = #- ENTER YOUR VALUE HERE -#
inputs.append(Indice_de_Claridade_KT)
parcialmente_nublado = #- ENTER YOUR VALUE HERE -#
inputs.append(parcialmente_nublado)
ceu_limpo = #- ENTER YOUR VALUE HERE -#
inputs.append(ceu_limpo)
nublado = #- ENTER YOUR VALUE HERE -#
inputs.append(nublado)
nn = NeuralNetwork()
outputs = nn.calculate_outputs(inputs)
print(outputs)
    main()
```