



NOVA

NOVA SCHOOL OF
SCIENCE & TECHNOLOGY

DEPARTAMENTO DE ENGENHARIA
ELETROTÉCNICA E DE COMPUTADORES

AGOSTINHO DOS SANTOS MUAMUHUNGA
Licenciado em Engenharia Eletrotécnica

MÉTODOS DE PREVISÃO DE PRODUÇÃO DE ENERGIA RENOVÁVEL: SOLAR FOTO- VOLTAICA

MESTRADO EM ENGENHARIA DE ENERGIAS RENOVÁVEIS
Universidade NOVA de Lisboa
Setembro, 2024



NOVA

NOVA SCHOOL OF
SCIENCE & TECHNOLOGY

DEPARTAMENTO DE ENGENHARIA
ELETROTÉCNICA E DE COMPUTADORES

MÉTODOS DE PREVISÃO DE PRODUÇÃO DE ENERGIA RENOVÁVEL: SOLAR FOTOVOLTAICA

AGOSTINHO DOS SANTOS MUAMUHUNGA

Licenciado em Engenharia Eletrotécnica

Orientador: Prof. Doutor Pedro Miguel Ribeiro Pereira
Professor auxiliar, Universidade NOVA de Lisboa

Júri:

Presidente: Doutor Nuno Manuel Ortega Amaro,
Professor Auxiliar, FCT-NOVA

Arguentes: Doutor Nuno Manuel Gonçalves Vilhena,
Professor Auxiliar, FCT-NOVA

Orientador: Doutor Pedro Miguel Ribeiro Pereira,
Professor Auxiliar, FCT-NOVA

MESTRADO EM ENGENHARIA DE ENERGIAS RENOVÁVEIS

Universidade NOVA de Lisboa

Setembro, 2024

Métodos de previsão de produção de energia renovável: solar fotovoltaica

Copyright ©Agostinho dos Santos Muamuhunga, Faculdade de Ciências e Tecnologia, Universidade NOVA de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade NOVA de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

Dedico a minha querida irmã.

AGRADECIMENTOS

Primeiramente, gostaria de endereçar os meus agradecimentos ao Professor Doutor Pedro Miguel Ribeiro Pereira pelo apoio e orientação prestados durante a realização deste trabalho. Manifesto também o meu profundo reconhecimento aos professores e funcionários da Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, pelo ensino de excelência e pelo apoio prestado ao longo da minha formação. Agradeço igualmente aos meus amigos e colegas de curso pela amizade e suporte inestimáveis, tanto nos momentos de dificuldade quanto nas ocasiões de celebração. As conversas e a partilha de ideias foram essenciais para o desenvolvimento deste trabalho. Por fim, expresso a minha gratidão à minha família, em especial aos meus pais, pelo amor, incentivo e apoio constantes durante todos os anos da minha jornada académica.

“Agimos como mortais perante tudo o que tememos
e como imortais perante tudo que cobizamos.” (Sénica).

RESUMO

A energia solar fotovoltaica tem-se destacado como uma das soluções mais promissoras e sustentáveis no panorama energético mundial, desempenhando um papel crucial na redução das emissões de gases com efeito de estufa e na transição energética. No entanto, a intermitência inerente à produção de energia solar, devido à variabilidade das condições meteorológicas, constitui um desafio significativo para a sua integração eficiente na rede elétrica. Neste contexto, os métodos de previsão de energia solar fotovoltaica surgem como ferramentas essenciais, permitindo que os operadores da rede antecipem a produção de energia e, dessa forma, tomem decisões mais informadas para manter o equilíbrio entre a oferta e a procura, planejar o armazenamento e reduzir os custos operacionais.

Esta dissertação explora os diversos métodos utilizados na previsão da produção de energia solar fotovoltaica, assim como os principais desafios inerentes a este processo. Os métodos analisados diferem em termos de complexidade e abordagem, abrangendo desde métodos físicos, estatísticos e híbridos até aos métodos baseados em inteligência artificial, os quais têm demonstrado uma grande capacidade para lidar com a complexidade dos dados e a sua natureza não linear.

Como parte da dissertação, foi realizado um estudo prático que envolveu o uso de um software de simulação, no qual diferentes configurações de Redes Neurais Artificiais foram treinadas e validadas. O objetivo foi identificar a configuração mais eficiente para a previsão da potência de energia solar fotovoltaica. O modelo foi avaliado com base em diversas métricas de desempenho, como o MAE, RMSE e MAPE, tendo apresentado um desempenho razoável na fase de previsão.

Este estudo oferece uma análise detalhada dos diversos métodos de previsão de energia solar fotovoltaica, enfatizando a relevância de selecionar corretamente o modelo e as suas configurações. Essa escolha é essencial para aumentar a precisão das previsões e, por conseguinte, facilitar uma melhor integração desta fonte de energia na rede elétrica.

Palavras chave: Sustentabilidade, variabilidade, métodos de previsão, energia solar fotovoltaica, transição energética.

ABSTRACT

Photovoltaic solar energy has established itself as one of the most promising and sustainable solutions in the global energy landscape, playing a crucial role in reducing greenhouse gas emissions and facilitating the energy transition. However, the inherent intermittency of solar energy production, due to the variability in weather conditions, presents a significant challenge for its efficient integration into the electrical grid. In this context, photovoltaic solar energy forecasting methods emerge as essential tools, allowing grid operators to anticipate energy production and thus make more informed decisions to maintain the balance between supply and demand, plan storage, and reduce operational costs.

This dissertation explores the various methods used in forecasting photovoltaic solar energy production, as well as the main challenges associated with this process. The methods analyzed vary in terms of complexity and approach, encompassing physical, statistical, and hybrid methods, as well as artificial intelligence-based methods, which have demonstrated a greater ability to handle the complexity of the data and its nonlinear nature.

As part of the dissertation, a practical study was conducted involving the use of simulation software, in which different configurations of Artificial Neural Networks were trained and validated. The objective was to identify the most efficient configuration for forecasting photovoltaic solar power output. The model was evaluated based on various performance metrics, such as MAE, RMSE, and MAPE, and demonstrated reasonable performance during the forecasting phase.

This study provides a detailed analysis of the various methods for forecasting photovoltaic solar energy, emphasizing the importance of correctly selecting the model and its configurations. This choice is essential for improving forecast accuracy and, consequently, facilitating better integration of this energy source into the electrical grid.

Keywords: Sustainability, variability, forecasting method, photovoltaic solar energy, energy transition.

ÍNDICE

1	INTRODUÇÃO.....	1
1.1	Motivação e Objetivo	7
1.2	Contribuições.....	8
1.3	Estrutura da Dissertação	8
2	ESTADO DA ARTE	9
2.1	Conceito de Energia Solar Fotovoltaico	9
2.1.1	Tecnologia Solar Fotovoltaica	10
2.2	Características de um Módulo Solar Fotovoltaico	12
2.2.1	Comportamento da Curva de Corrente e Tensão	12
2.3	Aspectos Determinantes na Produção de Energia Fotovoltaica	14
2.3.1	Irradiância Global Horizontal.....	15
2.3.2	Albedo	16
2.3.3	Ângulo Azimute, Ângulo Zénite e Altitude Solar.....	17
2.3.4	Inclinação e Sentido de Orientação dos Módulos Fotovoltaico.....	18
2.3.5	Sombreamento.....	18
2.4	Classificação dos Métodos de Previsão de Produção de Energia Solar Fotovoltaica.....	19
2.4.1	Métodos Físicos.....	20
2.4.2	Métodos Estatísticos.....	21
2.4.3	Métodos Híbridos.....	21

2.4.4	Métodos Diretos e Métodos Indiretos	22
2.4.5	Classificação de Acordo o Horizonte de Previsão	22
2.4.6	Previsão Determinística ou Probabilística.....	24
2.4.7	Previsão Fotovoltaica de Central Única e Regional.....	24
2.5	Casos de Estudos	25
3	MÉTODOS DE PREVISÃO DE ENERGIA SOLAR FOTOVOLTAICA	36
3.1	Método de Previsão Numérica de Tempo	36
3.2	Métodos Baseados na Previsão de Nuvens.....	37
3.2.1	Método de Imagem do Céu	38
3.2.2	Método de Imagem de Satélite.....	39
3.3	Método de Persistência.....	40
3.4	Métodos Baseados em Séries Temporais	41
3.4.1	Método de Média Móvel Exponencial Ponderada	41
3.4.2	Método de Média Móvel Autorregressiva	41
3.4.3	Método Autorregressivo Integrado de Média Móvel.....	43
3.4.4	Método de Regressão	44
3.5	Métodos Baseados em Aprendizagem de Máquina.....	45
3.5.1	Rede Neuronal Artificial	45
3.5.2	Máquinas de Vetor de Suporte	53
3.5.3	Máquina de Aprendizagem Extrema.....	55
3.6	Previsão Baseada em Métodos Híbridos	57
3.6.1	Abordagem Geral de Aprendizagem em Conjunto	58
3.6.2	Abordagem de Aprendizagem em Conjunto Baseada em Clusters.....	59
3.6.3	Abordagem de Aprendizagem em Conjunto Baseada em Decomposição	60
3.6.4	Abordagem de Aprendizagem em Conjunto Baseada em Resíduo.....	61
3.7	Parâmetros de Entrada dos Modelos de Previsão Fotovoltaicos	64
3.7.1	Normalização	66
3.7.2	Transformada de Wavelet	66

3.8	Métricas de Desempenho Para Avaliação da Precisão de Previsão	67
3.8.1	Erro Médio Absoluto e Erro Médio Quadrático.....	67
3.8.2	Raiz do Erro Médio Quadrático	68
3.8.3	Erro Médio Percentual Absoluto.....	68
3.8.4	Erro Médio Relativo.....	68
3.8.5	Erro Médio de Biés	69
3.9	Análise Comparativa dos Métodos de Previsão de Produção de Energia Solar Fotovoltaica	69
4	CASOS DE APLICAÇÃO: PREVISÃO DE PRODUÇÃO DE ENERGIA SOLAR FOTOVOLTAICA	71
4.1	Escolha do Modelo	72
4.2	Caracterização da Instalação Solar Fotovoltaica	73
4.3	Tratamento de Dados e Caracterização do Software.....	74
4.3.1	<i>Software</i> Utilizado.....	76
4.4	Treino e Validação do Modelo	78
4.5	Apresentação dos Resultados e Análise Comparativa.....	85
5	CONCLUSÕES E RECOMENDAÇÕES PARA TRABALHOS FUTUROS.....	94
5.1	Conclusões.....	94
5.2	Recomendações Para Trabalhos Futuros	95

ÍNDICE DE FIGURAS

Figura 1.1 - Instalações anuais fotovoltaica entre 2010 e 2022 e estimativas para 2023 (Jäger-Waldau, 2023).	2
Figura 1.2 - Capacidade cumulativa de Instalações Fotovoltaicas de 2010 até 2022 com projeção para 2023 (Jäger-Waldau, 2023).	3
Figura 1.3 - Capacidade instalada conectada à rede na UE (Chatzipanagi & Jäger-Waldau, 2023).....	4
Figura 1.4 - Capacidade solar fotovoltaica instalada em Portugal (<i>IRENA Renewable Energy Insights_Technologies</i> / <i>Tableau Public</i> , 2022).	5
Figura 1.5 - Produção de energia solar fotovoltaica em Portugal até outubro de 2023 (FICHA TÉCNICA Título: Estatísticas Rápidas Das Renováveis, 2023).	6
Figura 2.1 - Exemplo de uma célula fotovoltaica (Valente, 2011).	11
Figura 2.2 - Curva I-V de um módulo FV (Valente, 2011).	12
Figura 2.3 – Ilustração do ponto de potência máxima de um módulo solar fotovoltaico (Valente, 2011).	13
Figura 2.4 - Variação da corrente de saída em função da irradiância incidente (Xiao et al., 2007).	13
Figura 2.5 - Variabilidade da tensão de saída em relação a mudança de temperatura (Lima, 2014).	14
Figura 2.6 - variação da curva P-V com alteração da temperatura (Lima, 2014).	14
Figura 2.7 - Relação entre IGH e as IDN e ID (Patel et al., 2021).	15
Figura 2.8 - representação da IDN e ID durante o ano (Patel et al., 2021).	16
Figura 2.9 - Demonstração do albedo em corpos claros e escuros (Águia, 2016).	17
Figura 2.10 - Determinação dos ângulos por meio das coordenadas para um componente de radiação solar incidindo sobre um plano inclinado (Águia, 2016).	17
Figura 2.11 – Classificação dos métodos de previsão de energia solar fotovoltaica.	20

Figura 2.12 – Gráficos que ilustram a representação da produção FV nos meses de maio e janeiro respectivamente (Nespoli et al., 2018).....	29
Figura 3.1 – Representação dos métodos de imagem de satélite e imagem do céu (Rajagukguk et al., 2021).	38
Figura 3.2 – Etapas das previsões do método imagem do céu (Pelland et al., 2013).	39
Figura 3.3 – Movimento das nuvens em métodos baseados em satélite (Serrano, 2020).....	39
Figura 3.4 – Esquema geral de um modelo de previsão baseado no modelo ARMA (Sobri et al., 2018).....	43
Figura 3.5 – Estrutura básica de uma rede neuronal artificial (Chu et al., 2015).....	46
Figura 3.6 – Representação de um modelo matemático de uma ANN, adaptado de (Chu et al., 2015).....	47
Figura 3.7 - Diagrama do processo de modelagem para ANN (Sobri et al., 2018).	48
Figura 3.8 – Exemplo de uma estrutura de MLPNN adaptado de (Ahmed et al., 2020).	49
Figura 3.9 – Estrutura básica de uma rede RNN adaptado de (R. Ahmed et al., 2020).....	50
Figura 3.10 – Representação esquemática de uma RBFNN com uma única saída adaptado de (Johnsson, 2006).....	52
Figura 3.11 – Estrutura básica de uma SVM (Sobri et al., 2018).	55
Figura 3.12 – Fluxograma típico de uma máquina de aprendizado extremo (Sobri et al., 2018).....	56
Figura 3.13 – Estrutura básica de uma ELM adaptado de (Sobri et al., 2018).	56
Figura 3.14 – GELA (Guermoui et al., 2020).	59
Figura 3.15 – CELA (Guermoui et al., 2020).	60
Figura 3.16 – DELA (Guermoui et al., 2020).	61
Figura 3.17 – RELA (Guermoui et al., 2020).	62
Figura 4.1 - Fluxograma do processo de aplicação do modelo escolhido para a previsão.	71
Figura 4.2 – Imagem da (FCT/UNL) Obtida via google mapa.	73
Figura 4.3 – Conjunto de módulos utilizados para colheita de dados (Rogado, 2019).....	74
Figura 4.4 – Gráficos de médias horaria das amostras de irradiância e temperatura utilizada para previsão.	75
Figura 4.5 – Gráfico de média horária das amostras de potência utilizada para previsão.	76
Figura 4.6 – Configuração da Rede Neuronal Artificial usada para previsão	77
Figura 4.7 – Gráficos de regressão na fase de Treino e validação.....	79
Figura 4.8 – Gráfico de métricas de desempenho na fase de Treino.	81
Figura 4.9 – Gráfico de métrica de desempenhos na fase de validação.....	83
Figura 4.10 – Gráficos de regressão das melhores configurações nas fases de Treino e validação.....	83

Figura 4.11- Gráficos de previsão de produção de energia solar fotovoltaica na fase de previsão e validação.	84
Figura 4.12 – Previsão de energia solar fotovoltaica no dia 2 de novembro de 2013.	86
Figura 4.13 - Previsão de energia solar fotovoltaica no dia 3 de novembro de 2013.	88
Figura 4.14 - Previsão de energia solar fotovoltaica no dia 1 de dezembro de 2013.....	90
Figura 4.15 - Previsão de energia solar fotovoltaica no dia 2 de dezembro de 2013.....	92

ÍNDICE DE TABELAS

Tabela 2.1 – classificação resumida do horizonte de previsão de energia FV.....	23
Tabela 2.2 – Resumo dos casos de estudos onde foram aplicados alguns métodos de previsão.	33
Tabela 3.1 - Resumo de métodos baseados em ANN para previsão da potência FV.	52
Tabela 3.2 – Classificação dos métodos híbridos com base no modelo de pré-processamento de dados.....	58
Tabela 3.3 – Resumo dos métodos híbridos de acordo a classificação das abordagens.	62
Tabela 3.4 – Resumo dos métodos de pré-processamento de dados de entrada.	65
Tabela 3.5 – Análise comparativa dos diversos métodos de previsão de produção FV.....	70
Tabela 4.1 – características técnicas dos diferentes tipo de módulos solares, (Rogado, 2019).	74
Tabela 4.2 – Dados estatísticos das amostras de irradiância.....	75
Tabela 4.3 – Dados estatísticos das amostras de temperatura.	75
Tabela 4.4 – dados estatísticos das amostras referente a potência medida.	76
Tabela 4.5 – Erros de previsão na fase de Treino para as nove configurações.	80
Tabela 4.6 - Erros de previsão na fase de validação para as nove configurações.	82
Tabela 4.7 – Valores de potência real e prevista na fase de teste para o dia 2 de novembro..	85
Tabela 4.8 – Resultados das métricas de desempenho na fase de previsão no dia 2 de novembro.....	86
Tabela 4.9 - Valores de potência real e prevista na fase de teste para o dia 3 de novembro. .	87
Tabela 4.10 - Resultados das métricas de desempenho na fase de previsão no dia 3 de novembro.....	88
Tabela 4.11 - Valores de potência real e prevista na fase de teste para o dia 1 de dezembro.	89
Tabela 4.12 - Resultados das métricas de desempenho na fase de previsão no dia 1 de dezembro	90
Tabela 4.13 - Valores de potência real e prevista na fase de teste para o dia 2 de dezembro.	91

Tabela 4.14 - Resultados das métricas de desempenho na fase de previsão no dia 2 de dezembro	92
Tabela 4.15 – Comparação dos resultados das métricas de desempenho na fase de teste	93

SIGLAS

AIE	Agência Internacional de Energia
ANN	Artificial Neural Network
ARMA	Autoregressive Moving Average
ARIMA	Autoregressive Integrated Moving Average
CELA	Cluster-Based Ensemble Learning Approach
CSRM	Cumulative Sum Control Chart for Drift Detection
CDELA	Decomposition and Clustering-Based Ensemble Learning Approach
CVRMSE	Coefficient of Variation of Root Mean Squared Error
CSP	Concetrated Solar Power
DELA	Decomposition-Based Ensemble Learning Approach
DGEG	Direção Geral de Energia e Geologia
ELM	Extreme Learning Machine
EWMA	Exponential Weighted Moving Average
EELA	Evolution-Based Ensemble Learning Approach
ECMWF	European Centre for Medium-Range Weather Forecasts
EDDM	Early Drift Detection Method
FV	Energia solar Fotovoltaica
FFNN	Feedforward Neural Networks
FER	Fonte de Energia Renovável
GFS	Global Forecast System
IRENA	International Renewable Energy Agency
AI	Artificial Intelligence
IGH	Irradiância Global Horizontal
IDN	Irradiância Direta Normal
ID	Irradiância Difusa

JMA	Japan Meteorological Agency
LSTM	Long Short-Term Memory
LS-SVM	Least Squares Support Vector Machine
MOS	Statistical Output Models
MLPNN	Multilayer Perceptron Neural Networks
ML	Learning Machines
MAE	Mean Absolute Error
MSE	Mean Squared Error
MAPE	Mean Absolute Percentage Error
MBE	Mean Bias Error
MM5	Mesoscale Model Version 5
MTSAT	Multifunctional Transport Satellite
MFA	Multiple Factor Analysis
MEF	Mean Efficiency Factor
NOAA	Geostationary Operational Environmental Satellite for North and South America
NWP	Numerical Weather Prediction
NCEP	Environmental Forecasting Centre
nRMSE	Normalized Root Mean Squared Error
NARX	Nonlinear Autoregressive Exogenous Model
RNN	Recurrent Neural Network
RBFFNN	Radial Basis Function Neural Network
RME	Mean Relative Error
RMSE	Root Mean Squared Error
R	Correlation Coefficient
RGB	Red, Green, Blue
SVM	Support Vector Machine
SZA	Zenith Angle Function
SOM	Self-Organizing Map
SLFN	A Single Hidden Layer Feedforward Neural Network Algorithm
STC	Standard test condition
SI	Sky Imagery
SUFRAD	Surface Radiation Budget Network
TW	Wallet Transformation

INTRODUÇÃO

A evolução do sistema energético mundial está a ocorrer perante uma população em crescimento e com níveis de vida cada vez mais elevados, exigindo uma maior quantidade de energia (Sampaio & González, 2017). Ao mesmo tempo, é crucial que o mundo descubra métodos para diminuir as emissões de gases de efeito estufa (GEE) e garantir uma produção de energia elétrica de maneira sustentável. Considerando que a eletricidade representa a componente de maior expansão do sistema energético, torna-se fundamental, no contexto atual, a transição para sistemas de produção de energia renovável (Patel et al., 2021).

Segundo Agência Internacional de Energia (AIE, 2020), o sol surge como um dos recursos mais significativos para a geração de energia, alinhando-se com as futuras metas globais de "zero emissões líquidas".

Segundo Sampaio e González (2017), a utilização da energia solar por meio de módulos fotovoltaicos para a produção de eletricidade, é vista como um dos sectores mais promissor no âmbito das energias renováveis. A implementação destes sistemas no setor energético tem aumentado devido à redução nos preços dos módulos FV ao longo dos últimos anos (Poti et al., 2023). De acordo com Babatunde et al. (2023), estima-se que até 2040, a energia proveniente de fontes solar e eólica deverão participar com cerca de 48% na matriz global de geração de energia. Durante o intervalo entre 2009 e 2015, observou-se um crescimento de cerca de 100% na capacidade das centrais solares, de acordo com as estatísticas disponíveis. Esse aumento pode ser creditado às notáveis contribuições provenientes de vastos parques solares fotovoltaicos, tanto aqueles integrados à rede quanto os independentes, à adoção crescente da energia solar concentrada (CSP) e ao aumento da utilização de painéis FV em telhados (Babatunde et al., 2023).

Os investimentos globais em energias renováveis aumentaram 16% em 2022, atingindo a marca de 499 mil milhões de dólares norte-americano. A energia solar fotovoltaica (FV) registou um aumento de 47% nos investimentos, atingindo a marca de 301,5 mil milhões de dólares, representando assim 60% do total investido em energias renováveis (Jäger-Waldau,

2023). A capacidade em FV adicionada aumentou aproximadamente 40%, atingindo mais de 230 gigawatts-pico (GWp) em 2022 como ilustra a Figura 1.1, para as instalações anuais fotovoltaicas com estimativas para o ano de 2023 (Chatzipanagi & Jäger-Waldau, 2023). Isso situa-se no extremo inferior das previsões mais conservadoras (228 GWp) e no extremo superior das previsões mais otimistas (252 GWp).




Figura 1.1 - Instalações anuais fotovoltaica entre 2010 e 2022 e estimativas para 2023 (Jäger-Waldau, 2023).

A expectativa para o ano de 2023 apresenta um cenário notavelmente otimista no mercado fotovoltaico, com projeções anuais indicando uma nova capacidade instalada superior a 300 GW, conforme ilustrado na Figura 1.1. Essa previsão mais positiva sinaliza um impulso significativo no crescimento do setor. Consequentemente, essa expansão proposta elevaria a capacidade fotovoltaica total instalada cumulativa para 1,5 TWp, conforme representa a Figura 1.2 (Jäger-Waldau, 2023; Victoria et al., 2021). Estas perspectivas refletem um ambiente dinâmico e promissor no campo da energia solar, apontando para um futuro robusto e sustentável na expansão da capacidade fotovoltaica.




Figura 1.2 - Capacidade cumulativa de Instalações Fotovoltaicas de 2010 até 2022 com projeção para 2023 (Jäger-Waldau, 2023).

O destaque para a posição proeminente da China no cenário da energia fotovoltaica é incontestável, uma vez que detém uma capacidade instalada acumulada que ultrapassa os 400 GWp. Essa marca representa aproximadamente um terço da capacidade total instalada global, que atingiu 1185 GWp. Tal domínio reforça o papel fundamental desempenhado pela China na expansão e liderança no setor de energia solar, evidenciando sua significativa contribuição para a transição global para fontes de energia mais sustentáveis (Jäger-Waldau, 2023).

A União Europeia ocupa o segundo lugar em capacidade instalada global de energia fotovoltaica, detendo cerca de 18% da capacidade total, que equivale a 211 GWp. Esse número destaca o grande compromisso da União Europeia com fontes de energia renovável, o que representa uma parte significativa do panorama global e indica um forte impulso na transição para fontes mais limpas e sustentáveis. Por outro lado, os Estados Unidos possuem uma capacidade superior a 142 GW (12%) em energia fotovoltaica, demonstrando seu enorme papel no cenário da energia. Esses números refletem a importância crescente dessas regiões na promoção de soluções energéticas mais sustentáveis em escala global (Jäger-Waldau, 2023).

Em 2022, o mercado anual de energia fotovoltaica na UE experimentou um crescimento notável, atingindo uma expansão de quase 60%. A capacidade instalada ultrapassou a marca de 40 GWp, refletindo uma tendência ascendente significativa no setor. Doze países alcançaram a marca de mais de 1 GWp de capacidade acumulada em 2022, testemunhando aumentos significativos ao longo do ano. Os dados revelam que a Espanha viu sua capacidade aumentar de 8,0 para 8,2 GWp, enquanto a Alemanha experimentou um salto de 7,4 para 8,2 GWp. Outros países que registraram crescimentos notáveis incluem a Polônia, que passou de 4,8 para 5,0 GWp, os Países Baixos de 3,8 para 4,0 GWp, a França de 2,6 para 2,8 GWp e a Itália de

2,5 para 2,7 GWp. Além disso, Portugal viu sua capacidade aumentar de 2,4 para 2,6 GWp, a Grécia de 1,3 para 1,5 GWp, e Áustria de 1,2 para 1,4 GWp. Bélgica e Suécia também presenciaram um crescimento, atingindo 1,0 a 1,2 GWp cada. Esses números destacam o contínuo e robusto avanço da capacidade instalada de geração de energia fotovoltaica em toda a Europa (Jäger-Waldau, 2023). No que diz respeito à capacidade solar total instalada, Alemanha, Espanha, Itália, França e os Países Baixos emergem como líderes destacados na União Europeia como ilustra a Figura 1.3.

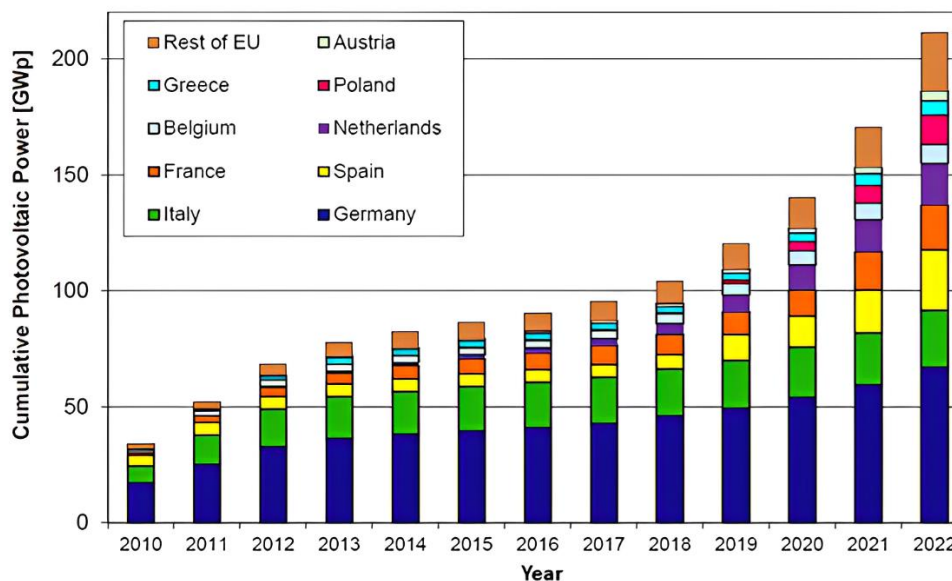


Figura 1.3 - Capacidade instalada conectada à rede na UE (Chatzipanagi & Jäger-Waldau, 2023)

Estes Estados-membros, ao alcançarem a supremacia na capacidade total de geração solar instalada na UE, desempenham um papel preponderante no impulso da transição energética e na mitigação da dependência de fontes energéticas convencionais em prol de alternativas sustentáveis. A liderança conjunta exercida por esses países também serve como estímulo para que outros Estados-membros da UE sigam esse modelo e intensifiquem seus investimentos em infraestrutura solar rumo a descarbonização e a independência energética. Diversos Estados-membros da União Europeia, que anteriormente apresentavam taxas de instalação fotovoltaica moderadas, transformaram-se em pontos cruciais para o rápido avanço do desenvolvimento fotovoltaico nos últimos dois anos. Países como Áustria, Itália, Portugal e Suécia têm experimentado um notável aumento na implementação de infraestrutura solar, indicando uma mudança significativa em suas estratégias e políticas energéticas dando o seu contributo na luta contra a descarbonização e redução de GEE. Esse fenômeno reflete o compromisso que Portugal e os demais membros assumiram em alcançar até 2030 uma capacidade fotovoltaica de 420 GW (Chatzipanagi & Jäger-Waldau, 2023).

Segundo o relatório da Direção-Geral de Energia e Geologia (DGEG 2023), a capacidade instalada para geração de eletricidade em Portugal registou um crescimento de aproxima-

damente 13,7% no período compreendido entre 2012 e 2022. Durante o mesmo período, observou-se um crescimento significativo, cerca de 56,1%, na capacidade instalada das centrais de geração de eletricidade oriundas de fontes limpas. Em contrapartida, a capacidade instalada das centrais de geração de eletricidade provenientes de fontes que utilizam combustíveis fósseis (não renováveis) apresentou uma redução de aproximadamente 36,3%. Entre as tecnologias renováveis implementadas em Portugal, destaca-se a tecnologia solar fotovoltaica como aquela que apresentou o maior crescimento. A potência instalada nessa modalidade registou um aumento expressivo, alcançando a marca de 2,6 GW como ilustra a Figura 1.4.




Figura 1.4 - Capacidade solar fotovoltaica instalada em Portugal (*IRENA Renewable Energy Insights_Technologies / Tableau Public, 2022*).

Até ao mês de outubro de 2023, é possível constatar um registo significativo relacionado à produção fotovoltaica em Portugal. Nesse contexto, a região de Alentejo desempenhou um papel crucial, sendo responsável por 35% da produção fotovoltaica total no país. Essa liderança é atribuída à média horária de produção solar na região, atingindo 1901 horas até o momento. Tal desempenho é notável, considerando que, no ano de 2022, a região registou uma média horária de produção de 1947 horas, evidenciando uma consistente contribuição para a produção nacional de energia fotovoltaica como mostra a Figura 1.5 (Observatório Da Energia, 2023).




Figura 1.5 - Produção de energia solar fotovoltaica em Portugal até outubro de 2023 (FICHA TÉCNICA Título: Estatísticas Rápidas Das Renováveis, 2023).

Com base nessas informações promissoras, percebe-se o compromisso de Portugal na luta contra as mudanças climáticas e o aquecimento global, bem como o empenho em alcançar as metas estabelecidas no acordo de Paris, que visam limitar o aumento da temperatura média global a menos de 2°C em relação aos níveis pré-industriais e esforçar-se para limitar o aumento a 1,5°C. Portugal está claramente seguindo em direção a uma matriz energética mais limpa, eficiente e ecologicamente sustentável.

1.1 Motivação e Objetivo

A presença abundante da radiação solar e a redução nos custos de instalação de fontes solar fotovoltaica constituem vantagens relevantes para a adoção deste método de produção de energia. No entanto, é importante salientar que a produção variável desta forma de energia é influenciada por diversos fatores (Patel et al., 2021).

As condições climáticas incertas representam a principal causa da variabilidade nos sistemas de produção fotovoltaicos, o que torna desafiador a integração eficiente das centrais solares fotovoltaicas na rede elétrica (Patel et al., 2021). No entanto, esta intermitência requer previsões precisas de forma a garantir uma integração eficaz na rede elétrica.

Os valores de produção e procura de energia elétrica precisam ser equilibrados para manter a estabilidade no funcionamento do sistema. A proximidade entre os valores da produção de energia nas centrais e os valores correspondentes à carga elétrica é essencial para que o operador do sistema possa programar reservas e operar o sistema de energia de forma eficiente e econômica (Monteiro et al., 2013). Portanto, para alcançar uma gestão eficiente da rede elétrica, torna-se fundamental contar com modelos de previsões eficientes. A previsão imprecisa da produção de energia solar pode acarretar perdas financeiras substanciais tanto para os operadores das centrais quanto para os investidores (Monteiro et al., 2013).

Assim sendo, é evidente que o problema da previsão da produção de energia solar é de extrema relevância, com implicações tanto ambientais quanto econômicas. Este problema exige uma investigação aprofundada dos métodos de previsão disponíveis, a fim de desenvolver abordagens mais eficazes para maximizar o aproveitamento do recurso solar como fonte de energia não poluente e sustentável. Como já foi referido anteriormente por Patel et al (2021), prever a quantidade de energia solar produzida é essencial para otimizar a integração desta fonte de energia ao sistema de transporte e distribuição (rede elétrica) e garantir a estabilidade da rede. Além disso, a previsão precisa da energia solar a produzir é fulcral para a viabilidade econômica de projetos solares, pois ajuda a evitar desequilíbrios entre a oferta e a procura.

Esta dissertação tem como foco a realização de uma análise bibliográfica abrangente dos diversos métodos utilizados para a previsão da geração de energia solar fotovoltaica. O objetivo deste trabalho é identificar e avaliar os métodos existentes e selecionar um método para aplicação em um caso prático. A revisão bibliográfica abordará uma variedade de técnicas de previsão, explorando as suas bases teóricas, aplicações práticas e desempenho histórico. O propósito é fornecer uma compreensão das vantagens e limitações inerentes a cada método. O enfoque será direcionado à análise dos métodos existentes, destacando os seus fundamentos teóricos e a sua eficácia, e será realizada uma análise comparativa entre eles.

1.2 Contribuições

O estudo e a análise desenvolvidos neste trabalho acerca dos métodos de previsão da produção de energia solar fotovoltaica disponíveis trarão contribuições valiosas e abrangentes para o setor. À medida que avançamos em direção a uma matriz energética mais sustentável e diversificada, a previsão precisa da geração de energia solar fotovoltaica assume um papel crucial na otimização do planejamento e na operação dos sistemas de energia.

Este trabalho visa contribuir de maneira significativa para o avanço na pesquisa sobre os métodos de previsão de energia solar fotovoltaica, oferecendo *insights* valiosos para orientar futuras investigações e aplicações práticas neste campo dinâmico e crucial.

1.3 Estrutura da Dissertação

A estrutura desta dissertação é composta por diversas partes. O capítulo inicial abrange a introdução na qual o tema é contextualizado, e são apresentadas as motivações que levaram a elaboração deste trabalho. Além disso, esse capítulo descreve os objetivos propostos e, delinea a organização subsequente do trabalho. No segundo capítulo, procede-se a uma revisão bibliográfica que aborda os conceitos fundamentais da energia solar fotovoltaica e os trabalhos existentes relativos aos métodos de previsão desta forma de energia, bem como suas diversas aplicações. No terceiro capítulo, são analisados detalhadamente os diferentes métodos de previsão de energia solar fotovoltaica, desde os físicos aos estatísticos e híbridos, assim como as métricas usadas para avaliar o desempenho dos modelos. No quarto capítulo, são apresentadas justificações da escolha do modelo aplicado ao caso prático, faz-se uma breve descrição do *software* utilizado e a apresentação dos resultados obtidos através das simulações. Por fim, no quinto capítulo, são apresentadas as conclusões e recomendações para trabalhos futuros.

ESTADO DA ARTE

O propósito principal deste capítulo é introduzir os conceitos fundamentais associados à produção de energia solar fotovoltaica, as tecnologias envolvidas, os principais fatores que influenciam a produção e os métodos de previsão utilizado para prever a geração de energia solar fotovoltaica. Essa abordagem será embasada em diversas fontes bibliográficas e artigos científicos provenientes de diferentes autores e geografias.

2.1 Conceito de Energia Solar Fotovoltaico

Com base na radiação solar é possível produzir energia elétrica por meio do efeito fotovoltaico. Este fenômeno é definido por Castro (2018), como uma ocorrência observada em determinados materiais que possuem a capacidade de gerar uma corrente elétrica quando expostos à luz. A descoberta deste fenômeno remonta a 1839 e é creditada a Alexandre Edmund Becquerel. Este fenômeno envolve um processo quântico de excitação de elétrons, resultando na formação de pares elétron-lacuna que são empregados na condução de corrente elétrica quando há a presença de um campo elétrico (Serrano, 2020).

Conforme destacado por Serrano (2020), a energia solar fotovoltaica é amplamente utilizada na atualidade em uma variedade de contextos, desde o fornecimento de energia para diferentes aparelhos e residências até a geração de eletricidade em larga escala através de redes de distribuição. Esse tipo energia converte diretamente a luz solar em energia elétrica, empregando células fotovoltaicas como sua unidade básica de conversão. Essa tecnologia envolve a transformação da radiação solar em eletricidade, utilizando células fotovoltaicas que são organizadas em módulos fotovoltaicos para este propósito. Portanto, estes dispositivos destacam-se pela sua simplicidade de design e são facilmente operáveis. Adicionalmente, possuem a capacidade de obter resultados significativos a partir de quantidades menores de insumos. Como resultado, são amplamente utilizados em várias aplicações em todo o mundo (Kannan & Vakeesan, 2016).

A energia solar que chega à Terra é verdadeiramente imensurável. Calcula-se que as reservas globais de petróleo alcançam cerca de $1,7 \times 10^{22}$ joules, correspondendo à energia recebida pela Terra em apenas 1,5 dias. Por sua vez, o sol proporciona à Terra, a cada hora, uma quantidade de energia equivalente ao consumo humano anual, estimado em cerca de $4,6 \times 10^{20}$ joules (Castro, 2018). Salienta-se que essa forma de energia é considerada uma alternativa altamente viável para um futuro próximo, em contraposição ao emprego de recursos fósseis. Tal escolha contribui para a diminuição das emissões dos gases causadores do efeito estufa e, por conseguinte, para a mitigação do aquecimento global.

Em comparação com as demais energias renováveis, a energia solar fotovoltaica revela menor propensão a causar danos ambientais no local de produção, ao contrário do que sucede com a energia gerada por hidroelétricas. Na construção destas últimas, ocorre a alteração do curso do rio, resultando na submersão de vastas áreas destinadas à produção de alimentos e florestas. Outro aspeto crucial é o custo operacional, que, no caso da geração hidroelétricas, é elevado quando contrastado com o custo operacional de um central solar. Embora a energia solar seja amplamente disponível, a produção em dias sem sol reduz-se consideravelmente, ao passo que a quantidade de água em reservatórios é muito reduzida em período de escassez. Diferente da energia eólica, a energia solar FV manifesta-se de maneira reservada, viabilizando a sua geração em áreas edificadas mediante a instalação de painéis solares nas edificações. (Sampaio & González, 2017).

As restrições inerentes aos sistemas FV não impedem a rápida instalação de uma central, apta a produzir vários megawatts (MW) em menos de um ano. Dado que os impactos ambientais são reduzidos nestas centrais, tais sistemas dispensam a realização de análises prévias que exigem avaliações detalhadas, ao contrário dos sistemas que danificam bastante o meio ambiente. (Silveira et al., 2013).

Nos últimos anos, tem havido um incremento notável no interesse pela produção de energia fotovoltaica, devido à sua praticabilidade e adequação em edifícios. Este aumento é atribuível à capacidade desta tecnologia em diminuir os custos ligados ao consumo de energia.

2.1.1 Tecnologia Solar Fotovoltaica

Como referido anteriormente por Castro (2018), a energia solar fotovoltaica converte a radiação proveniente do sol em energia elétrica por meio do efeito fotovoltaico. Considerando que essa conversão é realizada por meio de células fotovoltaicas.

A energia solar fotovoltaica é caracterizada por células constituídas por semicondutores, sendo o silício um exemplo destes materiais. O silício apresenta propriedades situadas entre as de um condutor e as de um isolante (Sampaio & González, 2017).

O silício puro, por não possuir elétrons livres, o que o torna um condutor elétrico fraco, é dopado com outros elementos. Ao ser dopado com fósforo, o silício adquire elétrons livres (camada N). Ao ser dopado com boro, o silício adquire propriedades opostas, isto é ausência de elétrons que é considerado um buraco, comportando-se como carga positiva (camada P) conforme representado na Figura 2.1. Cada célula é composta por material do tipo N, que constitui a camada fina, e por material do tipo P, correspondente à camada mais espessa. (Castro, 2018; Sampaio & González, 2017).




Figura 2.1 - Exemplo de uma célula fotovoltaica (Valente, 2011).

De acordo com Subtil Lacerda & Van Den Bergh (2016), atualmente, assiste-se a uma multiplicidade de tecnologias utilizadas em células solares fotovoltaicas, utilizando materiais diversos, com a previsão de um aumento considerável no número destas tecnologias nos próximos tempos. As tecnologias associadas às células solares fotovoltaicas são frequentemente agrupadas em três gerações, tendo em conta os materiais utilizados e o estágio de desenvolvimento comercial.

O sistema FV de primeira geração, já consolidados no mercado, adotam a técnica do silício cristalino (c-Si), quer seja na sua estrutura cristalina simples (sc-Si) ou multicristalina (mc-Si). Pelo contrário, as tecnologias de segunda geração tem evidenciado um crescimento significativos no mercado. Este crescimento é impulsionado, principalmente, pelo considerável potencial de redução de custos que apresentam, mas também pela permeabilidade e flexibilidade nos processos de produção. Nesta categoria de tecnologia, os materiais mais comuns são o telureto de cádmio (CdTe), com uma quota de mercado de 8%, o silício amorfo (a-Si), com 5%, e o disseleneto de cobre-índio-gálio (CIGS), com menos de 1% (Castro, 2018; Sampaio & González, 2017).

Enquanto, as tecnologias de terceira geração integram inovações que estão atualmente em fase de investigação, contudo, com um grande potencial de progresso e, eventualmente, de inovação disruptiva. Entre estas, destacam-se as células sensibilizadas por corante, as células orgânicas e as nanoantenas (Castro, 2018; Sampaio & González, 2017).

2.2 Características de um Módulo Solar Fotovoltaico

2.2.1 Comportamento da Curva de Corrente e Tensão

A metodologia mais reconhecida para caracterizar uma célula FV ou módulo reside na obtenção da sua curva de resposta, a qual fornece dados relativos à tensão, corrente e potência. Estas respostas do dispositivo são identificadas como curva I-V como mostra a Figura 2.2. Estas curvas características disponibilizam informações cruciais sobre o estado da célula FV para qualquer módulo nas condições de teste padrão (STC), nessas condições a Irradiância possui um valor de 1000W/m^2 e temperatura 25°C , e são diretamente influenciadas pela temperatura e pela radiação incidente sobre o módulo ou célula (Morales-Aragonés et al., 2021; Valente, 2011).




Figura 2.2 - Curva I-V de um módulo FV (Valente, 2011).

Ao analisar o gráfico da curva I-V da célula, considera-se que, quando o módulo está exposto à luz solar, ou seja, sob incidência direta do sol, presume-se que ele gera corrente positiva. Nessa circunstância, aplica-se uma tensão positiva nos terminais do módulo.

De acordo com Valente (2011), a determinação do ponto de operação de um painel solar, ligado a uma resistência variável R , é definida através da interseção da curva I-V do módulo FV com a linha de carga. Se a carga for resistiva, sua característica é representada por uma linha reta com inclinação $I/V=1/R$. O valor da potência fornecida pela carga depende da resistência. O módulo fotovoltaico pode funcionar como fonte de corrente constante entre os pontos MN ou como fonte de tensão constante entre os pontos PS, dependendo da resistência. A transferência ótima de potência ocorre entre os pontos NP, onde as coordenadas I_{max} e V_{max} oferecem a máxima potência disponível. Ponto máxima de potência.

O ponto de máxima potência representa o estado ideal de operação, tornando-se o ponto desejado para o funcionamento do módulo. Mesmo neste ponto otimizado, o desempenho do painel é influenciado por condições ambientais, nomeadamente a temperatura e a incidência

da radiação solar. A Figura 2.3 ilustra a curva do ponto máximo de potência do módulo FV (Lima, 2014; Valente, 2011).

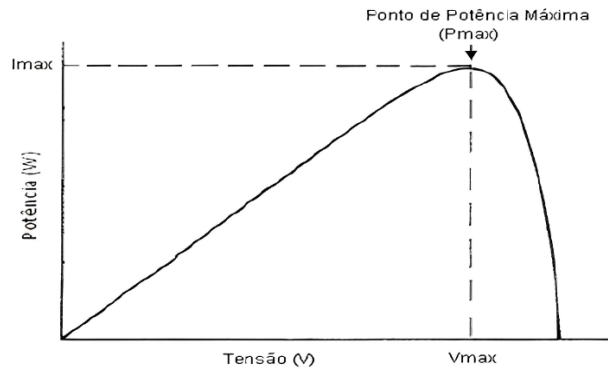


Figura 2.3 – Ilustração do ponto de potência máxima de um módulo solar fotovoltaico (Valente, 2011).

Há uma mudança na corrente de saída do módulo para valores diferentes de tensão quando se trata da radiação solar. A corrente aumenta em proporção direta à radiação, enquanto a tensão permanece relativamente estável, conforme ilustrado na Figura 2.4 (Lima, 2014; Xiao et al., 2007).

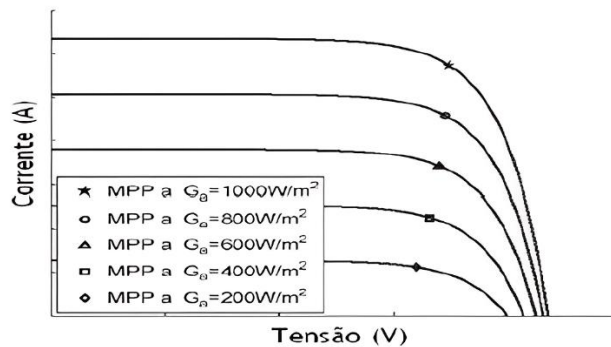


Figura 2.4 - Variação da corrente de saída em função da irradiância incidente (Xiao et al., 2007).

Conforme evidenciado na Figura 2.4, observa-se que a corrente diminui à medida que a radiação diminui. De maneira análoga, o ponto de potência máxima (P_{max}) também experimenta uma redução proporcional à diminuição da radiação (Lima, 2014; Valente, 2011).

Observa-se um padrão semelhante em relação à temperatura, uma vez que a sua variação provoca uma alteração na tensão de saída para qualquer valor de corrente. À medida que a temperatura aumenta a tensão diminui, mantendo uma irradiância constante. A relação entre a tensão e a temperatura é inversamente proporcional, como se observa na Figura 2.5 (Valente, 2011).

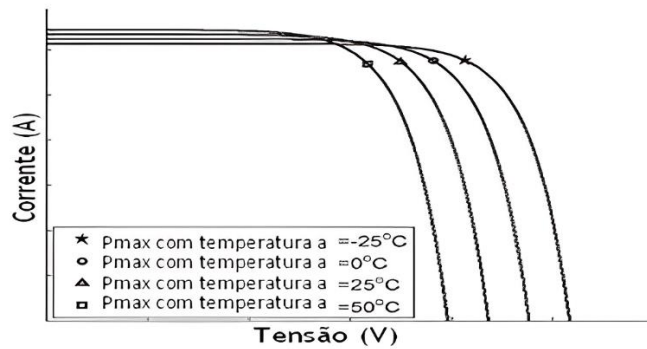


Figura 2.5 - Variabilidade da tensão de saída em relação a mudança de temperatura (Lima, 2014).

Ao analisar a representação gráfica da Figura 2.5, nota-se que a magnitude da tensão diminui à medida que a temperatura aumenta, e o ponto de potência máxima (P_{max}) também sofre alterações (reduz-se) com o aumento da temperatura.

Adotando a mesma linha de raciocínio, é essencial manter o ponto de operação em proximidade ao ponto de potência máxima (P_{max}) para assegurar a eficiência máxima do painel. A potência é de igual modo influenciada pelas condições atmosféricas, pois ela é representada pela seguinte expressão $P = V \cdot I$, conforme representado na figura 2.6. (Lima, 2014; Valente, 2011; Xiao et al., 2007).




Figura 2.6 - variação da curva P-V com alteração da temperatura (Lima, 2014).

2.3 Aspectos Determinantes na Produção de Energia Fotovoltaica

Factores meteorológicos como a temperatura ambiente, a quantidade de radiação solar e a velocidade do vento, têm grande impacto na produção da energia solar FV (Castro, 2018). Essas variáveis influenciam de maneira específica a produção devido à natureza dos equipamentos utilizados. Como valores de referência, a temperatura e a irradiância são utilizadas como variáveis que determinam as características elétricas dos módulos FV. Em função das

condições de operação, a tensão e a corrente dos painéis variam. Com base nos valores antecipados de temperatura e irradiância, é essencial analisar a interdependência entre estas duas variáveis, a fim de obter uma estimativa da energia produzida. Além das variáveis meteorológicas, o rendimento dos equipamentos, o ângulo com que a radiação incide sobre o módulo, o sombreamento, as presenças de nuvens também afetam a produção de energia fotovoltaica. O propósito desta parte é explicar os fatores que determinam a produção de energia solar.

2.3.1 Irradiância Global Horizontal

A irradiância global horizontal (IGH) representa a fração da radiação solar que atinge a atmosfera como mostra a Figura 2.7. Dividida em duas partes fundamentais, essa irradiância compreende a irradiância normal direta (IDN) e a irradiância difusa (ID).

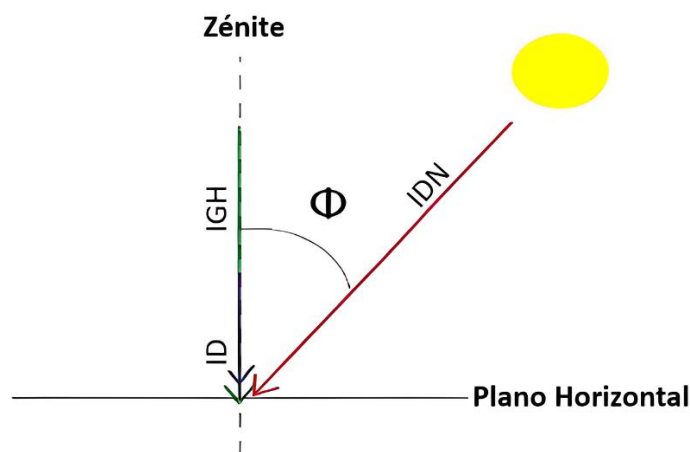


Figura 2.7 - Relação entre IGH e as IDN e ID (Patel et al., 2021).

A irradiância normal direta, refere-se à radiação solar incidente numa superfície perpendicular aos raios solares, gerando sombras nítidas quando encontram obstáculos, por outro lado, as ID é a parte da radiação solar que, após atravessar a atmosfera, se dispersa em várias direções devido à interação com partículas e moléculas no ar (como poeira, água e gases). Esta radiação chega à Terra de maneira uniforme, sem seguir uma trajetória direta do Sol. Mediante fenómenos como a dispersão de gases atmosféricos, absorção e reflexão, é possível discernir a diferença entre estas duas componentes do IGH (Patel et al., 2021; Vignola et al., 2012). A Figura 2.8 ilustra a irradiância direta e difusa ao longo do ano, destacando que os meses de maio a julho apresentam a máxima radiação.

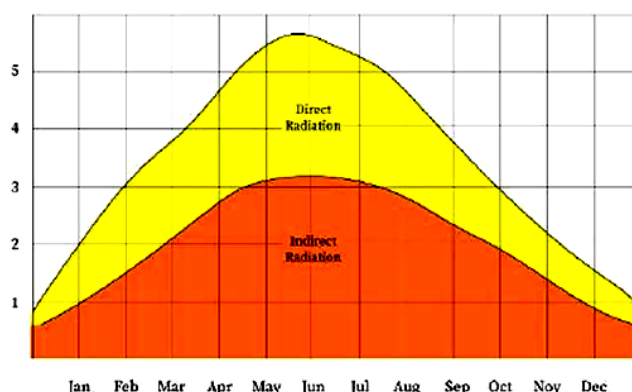


Figura 2.8 - representação da IDN e ID durante o ano (Patel et al., 2021).

Em dias de céu limpo, a radiação solar é dominada pela componente direta, ao passo que em dias mais nublados, sobretudo em épocas do ano com temperaturas mais baixas, a radiação solar é quase especificamente difusa. Os fatores atmosféricos, como nuvens, humidade, estação do ano e o momento do dia, desempenham um papel crucial na análise das duas componentes da IGH. De acordo com Vignola et al., (2012) a quantidade de radiação solar recebida varia conforme a meteorologia e os fatores atmosféricos citados anteriormente:

- Em dias claros, a radiação direta representa 60% do valor máximo, enquanto a radiação difusa representa 30% do mesmo valor.
- Em dias nublados, a radiação direta atinge 0%, enquanto a radiação difusa representa 60% do valor máximo.

2.3.2 Albedo

O Albedo representa a fração da radiação incidente na superfície terrestre que é refletida, sendo resultado das características do solo. Trata-se de uma magnitude complexa influenciada por diversas características ambientais, quer dependentes quer independentes do tipo de solo (Águia, 2016; Patel et al., 2021).

O entendimento do albedo revela detalhes acerca da reflexão da radiação e da interação entre a radiação direta e difusa. Em geral, uma maior taxa de albedo indica uma reflexão solar mais intensa e um aumento proporcional na radiação difusa. O albedo varia entre 0 e 1 da seguinte maneira:

- O valor 0 corresponde a um corpo negro, indicando que ele absorve 100% da radiação incidente.
- Valores de albedo entre 0,1 e 0,2 sugerem a presença de superfícies de solo com tonalidades escuras.
- Valores compreendidos entre 0,4 e 0,5 indicam a presença de superfícies lisas e de tonalidade clara.

A Figura 2.9 apresenta um exemplo claro de como os corpos absorvem a radiação solar. Nota-se que os corpos de cores escuras absorvem quase toda a radiação incidente, ao contrário dos corpos de cores claras, que refletem a maior parte dela.

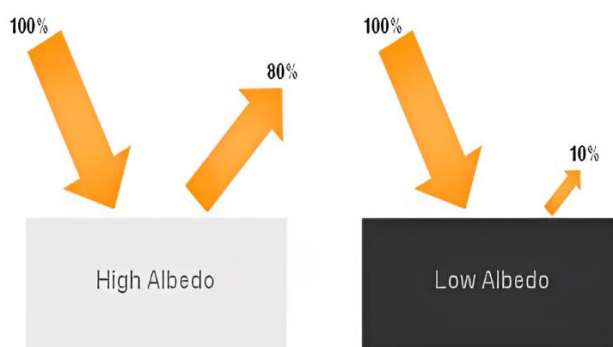


Figura 2.9- Demonstração do albedo em corpos claros e escuros (Águia, 2016).

2.3.3 Ângulo Azimute, Ângulo Zênite e Altitude Solar.

Otimizar a radiação incidente na superfície dos módulos é essencial para aumentar a produção fotovoltaica, o que requer encontrar uma solução para a orientação adequada dos mesmos.

Representada por várias variáveis, a localização da posição do sol pode ser determinada em qualquer local, o que constitui uma solução fundamental para otimizar a orientação dos painéis solares, como ilustra a Figura 2.10.

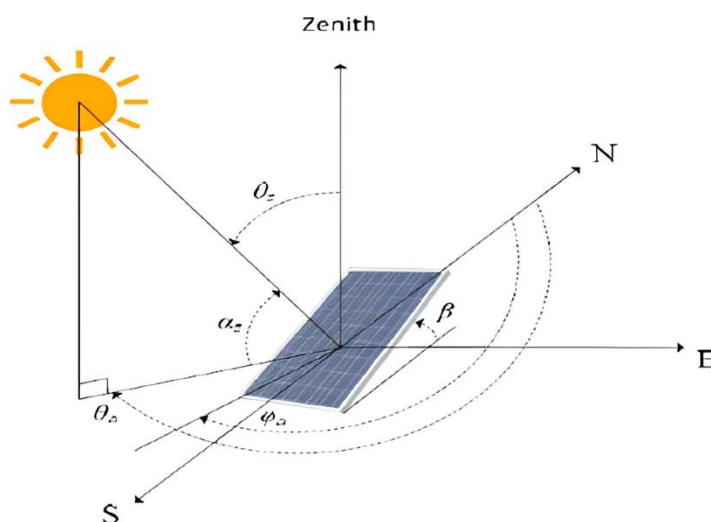


Figura 2.10 - Determinação dos ângulos por meio das coordenadas para um componente de radiação solar incidindo sobre um plano inclinado (Águia, 2016).

De acordo com (Patel et al., 2021), o ângulo azimute (θ_a) é a medida angular entre a projeção do centro do Sol no plano horizontal e a direção sul verdadeira. No hemisfério norte, ao fixar uma posição, é possível determinar o valor do ângulo azimute para os outros hemisfé-

rios. Os azimutes podem ter um intervalo de variação de 0° a 360° . Com base na referência estabelecida no hemisfério norte, o azimute sul tem um valor de 0° , enquanto o norte é 180° , para leste utiliza-se 90° e para o oeste é 270° (Lima, 2014).

O ângulo zenital (θ_z) representa a inclinação entre a posição solar e a vertical em relação aos painéis solares, oscilando de 0° a 180° . Este ângulo corresponde à distância entre a radiação solar direta no plano e o ponto zênite. O zênite é uma referência imaginária atravessada por um eixo vertical também imaginário, projetado a partir do painel fotovoltaico.

A elevação solar, (α_z), é o ângulo entre a radiação direta no plano e o plano horizontal. Embora possa variar entre -180° e 180° , quando o painel está bem orientado, o valor é inferior a 90° .

2.3.4 Inclinação e Sentido de Orientação dos Módulos Fotovoltaico

Para obter diferentes níveis de radiação e, conseqüentemente, produção fotovoltaica, determina-se a orientação em instalações solares. No hemisfério norte, a direção ideal para maximizar a radiação útil é alinhada com o Sul geográfico, enquanto no hemisfério sul, a orientação ideal para maximizar a radiação útil é alinhada com o Norte geográfico. É possível explorar telhados com orientações menos ideais, mas é necessário considerar a menor irradiação nessa situação. A integração de tecnologias solares nas fachadas, com um ângulo de inclinação de 90° , resulta na diminuição da energia produzida em consequência à significativa redução da intensidade da radiação. Nessa situação, a determinação final para a edificação da fachada utilizando certos materiais é consideravelmente afetada pela visibilidade da instalação e pelas formas como os equipamentos foram projetados.

Diversos estudos foram conduzidos para calcular os ângulos que maximizam a produção de energia elétrica em sistemas FV fixos conectados à rede. Em Portugal, por exemplo, foi observado que esse ângulo é aproximadamente 33° em todo o território. Essa informação é crucial para otimizar o desempenho dos sistemas fotovoltaicos e garantir uma produção elétrica eficiente (Castro, 2018).

2.3.5 Sombreamento

A projeção de um sistema fotovoltaico é afetada pelo sombreamento, o qual pode comprometer a eficiência e a segurança do sistema. Na maioria dos casos, o sombreamento é temporário e imprevisível, que resultam de fenômenos naturais como árvores, nuvens e edifícios próximos. No entanto, o impacto do sombreamento varia, sendo transitório no caso das nuvens, mas permanente quando causado por poeira ou folhas nos módulos fotovoltaicos. A inclinação dos módulos pode facilitar a remoção dessa sujidade.

2.4 Classificação dos Métodos de Previsão de Produção de Energia Solar Fotovoltaica

De acordo com Ghislain Agoua et al. (2018), nas últimas décadas, houve um aumento considerável na incorporação da energia FV na matriz energética de diversos países. Isso se deve, em grande parte, às políticas que promovem o uso de energias renováveis e à redução significativa dos custos dessa tecnologia específica. No entanto, a geração de energia solar FV é altamente variável, uma vez que, depende diretamente das condições meteorológicas, o que impõe desafios adicionais aos operadores de redes de energia. Lidar com esses desafios requer a capacidade de observar e prever com precisão os níveis de produção. Atualmente, a previsão precisa da produção de energia das centrais fotovoltaicas é considerada um requisito fundamental para a expansão em larga escala da energia fotovoltaica na rede elétrica.

Por exemplo em mercado diário de eletricidade como é em vários países, grandes centrais de energias renováveis (FER) podem operar como qualquer outro fornecedor de eletricidade, que oferecem sua produção ao mercado por meio de licitações de energia. Parques eólicos e grandes centrais fotovoltaicas, que geram energia elétrica, utilizam vários métodos de previsões para planejar suas propostas de venda. Contudo, enfrentam um desafio nos mercados elétricos, se a produção real de energia não corresponder à oferta inicialmente comunicada ao operador do mercado, o produtor pode receber remunerações mais baixas para as horas em que houve essa divergência (Monteiro et al., 2013). Portanto, é de suma importância para os produtores de energia FV possuírem sistemas de previsão de qualidade elevada. Esses auxiliam na prevenção de sanções nos mercados elétricos e na otimização dos lucros.

Nos últimos anos, as soluções apresentadas e divulgadas são distintas, abrangendo os métodos físicos, estatísticos ou híbridos (Sobri et al., 2018). Dentre essas alternativas, merece destaque a aplicação de técnicas fundamentadas em aprendizagem de máquinas, com enfoque em Redes Neurais Artificiais (ANN) (Zhou et al., 2019). Devido à sua ampla aplicabilidade, essas técnicas podem contribuir para a busca de soluções que tornarão as aplicações de energia solar cada vez mais praticável.

Assim sendo, os métodos de previsão de energia solar fotovoltaica podem ser classificados em métodos físicos, métodos estatísticos e métodos híbridos. Cada um destes grupos pode ser subdivididos em diversas categorias como ilustra a Figura 2.11 (Yang et., al 2023).

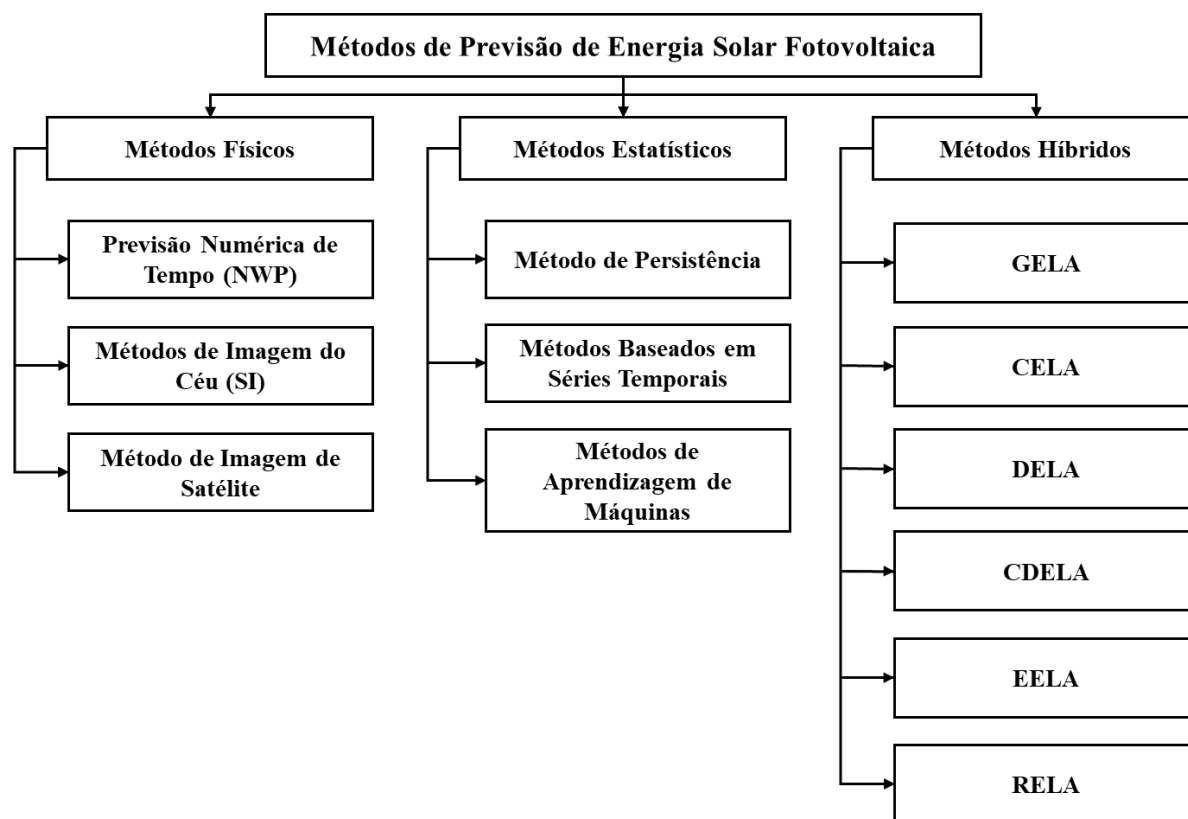


Figura 2.11 – Classificação dos métodos de previsão de energia solar fotovoltaica.

2.4.1 Métodos Físicos

A previsão da produção de energia solar fotovoltaica, através de métodos físicos, baseia-se em parâmetros meteorológicos, como a cobertura de nuvens, a temperatura ambiente e a irradiância solar, para simular a conversão da luz solar em eletricidade. Estes elementos são utilizados como entrada em equações físicas que estimam a quantidade de energia produzida. Inicialmente, os modelos físicos são relativamente simples, considerando apenas a irradiância solar global, mas tornam-se mais complexos à medida que são incluídos outros fatores meteorológicos (por exemplo, cobertura de nuvens, temperatura ambiente, etc.). As informações específicas sobre uma localização particular, parâmetros climáticos, orientação dos painéis e dados do passado são utilizadas no projeto dos modelos físicos. Este método é especialmente sensível a mudanças bruscas e significativas nas condições meteorológicas. No entanto, os modelos físicos costumam ser mais precisos quando o clima se mantém estável. Exemplos de métodos físicos incluem o modelo NWP, os modelos de imagem de céu (SI) e a captura de imagens via satélite (Iheanetu, 2022).

2.4.2 Métodos Estatísticos

Os métodos estatísticos são técnicas que se baseiam em dados históricos para identificar padrões e correlações, que permitem prever a geração de energia em função de variáveis relacionadas. Esses métodos não consideram diretamente os parâmetros físicos da atmosfera, mas utilizam dados meteorológicos e de desempenho dos sistemas fotovoltaicos para modelar as relações entre diferentes variáveis (Sobri et al., 2018).

Técnicas estatísticas são frequentemente desenvolvidas a partir dos princípios de persistência ou séries temporais aleatórias. É crucial estabelecer a relação entre as variáveis de entrada e a potência de saída correspondente para o desenvolvimento de modelos de previsão de energia fotovoltaica, utilizando métodos científicos validados. (Iheanetu, 2022).

Os parâmetros meteorológicos que impactam a potência de saída na produção de energia FV, como irradiância, humidade, precipitação, vento, cobertura de nuvens e temperatura, são tidos como dados iniciais para o algoritmo de previsão, designados variáveis ou vetores de entrada.

Nesta categoria, algumas técnicas empregadas incluem análise estatística convencional, bem como inteligência artificial (IA) ou aprendizado de máquina (ML). As técnicas tradicionais de previsão aplicam análise de regressão aos dados de séries temporais para criar modelos de previsão de potência de saída FV (Wang et al., 2016). Em relação às técnicas de IA, exemplos incluem ANN, máquinas de vetores de suporte (SVM), máquina de aprendizado extremo e entre outras (R. Ahmed et al., 2020; B. Yang et al., 2023). Importante mencionar que há diversas modificações aplicadas às técnicas de IA mencionadas.

2.4.3 Métodos Híbridos

A maior parte dos investigadores concentraram-se em previsões solares através de modelos únicos como é citado por B. Yang et al., (2023). Contudo, a confiabilidade de um modelo único na previsão nem sempre é garantida para diferentes situações. Uma razão para o surgimento de modelos híbridos é a possibilidade de melhorar a precisão da previsão ao integrar diferentes métodos.

De acordo com Iheanetu (2022), a abordagem híbrida engloba técnicas estatísticas e físicas para realizar previsão. Inicialmente, é aplicado o modelo físico disponibilizado pelos fabricantes dos módulos fotovoltaicos, seguido pela utilização de uma técnica estatística no resultado para aprimorar a precisão. A combinação de duas técnicas, sejam elas físicas ou estatísticas, constitui também um modelo previsão híbrido.

Em virtude do progresso nas metodologias de medição, que ao longo dos anos têm gerado volumes consideráveis de dados, houve igualmente avanços nas tecnologias de análise

de dados que processam essa informação. As seções seguintes apresentam classificações que complementam as categorias principais discutidas anteriormente.

2.4.4 Métodos Diretos e Métodos Indiretos

A previsão direta é um método que utiliza dados históricos de produção de energia FV para prever a produção futura. Neste modelo, as relações entre as variáveis de entrada, como condições meteorológicas e características do sistema, e a potência elétrica gerada são estabelecidas diretamente a partir da análise de dados passados.

Por outro lado, as previsões indiretas recorrem a dados de fontes externas ao módulo. Esta abordagem envolve duas etapas principais: Primeiro, são modelados os fatores climáticos que influenciam a produção de energia solar, como a irradiação solar e a temperatura. Na segunda etapa, os resultados dessa modelagem são utilizados para prever a potência de saída do sistema fotovoltaico (El Hendouzi & Bourouhou, 2020).

A diferença entre esses dois métodos reside no facto de que o método direto não precisa efetuar o cálculo do valor da irradiação solar em uma etapa intermediária.

Segundo Iheanetu (2022), diversas técnicas de previsão indireta foram utilizadas em diferentes escalas temporais para antecipar a produção de energia FV. Esses métodos incluem a previsão baseada NWP, ANN, ANN híbridas e técnicas baseadas em imagem. Vários *softwares* têm adotado esses métodos para prever a produção de energia FV. Programas como PVGIS, PVWatts, Helioscope, RETScreen, PVSol e PVsyst utilizam a previsão de irradiação solar e dados meteorológicos associados como entrada para as previsões. Eles implementam esses dois métodos para antecipar a produção de energia FV do dia seguinte e, concluiu-se que entre eles, o método baseado em previsão direta apresenta maior eficácia em relação ao método indireto.

De acordo com Gandoman et al (2016), foram examinadas várias fontes de literatura relacionadas aos métodos de previsão de curto prazo para estimar a potência de saída solar FV, tendo como base os efeitos causados pela cobertura de nuvens. Foi evidenciado que os métodos indiretos exibem maior exatidão durante a previsão, pois estes métodos levam em conta as perdas específicas do local antes de estimar os valores de rendimento que resultam em previsões mais fiáveis.

2.4.5 Classificação de Acordo o Horizonte de Previsão

De acordo com Ahmed et al (2020), o período para o qual se faz a previsão da saída de energia FV é denominado horizonte de previsão. A exatidão da previsão varia de acordo com o horizonte temporal futuro, que mantém os parâmetros do modelo inalterados. Em função do

horizonte de previsão de produção de energia FV na saída, esses horizontes podem ser categorizados em quatro tipos, de acordo com C. Liu et al., (2022):

- **Muito curto prazo** - Quando a previsão é para um período extremamente breve, isso significa que o horizonte de previsão é de alguns segundos a um minuto, porém menos do que uma hora;
- **Curto prazo** – Este tipo de previsão é aplicada quando se pretende realizar previsão de energia FV para um intervalo que varia entre uma a várias horas;
- **Médio prazo** - A categoria de previsão de médio prazo abrange um período que corresponde entre uma semana a um mês;
- **Longo prazo** - Uma previsão de longo prazo é caracterizada quando o horizonte de previsão para a produção de energia FV corresponde entre um mês a um ano.

Por exemplo, os métodos de previsão de muito curto prazo, são aplicados quando se pretende garantir o cumprimento, planeamento e distribuição da energia produzida, que contribui também para a segurança na operação da rede elétrica. Por sua vez, os métodos de previsão de médio prazo geralmente são aplicados na otimização do planeamento do sistema de energia e do cronograma de manutenção, prevendo a disponibilidade de energia no futuro. Por último, aplicam-se os métodos de longo prazo na produção de energia, no planeamento, na distribuição e na transmissão. Contudo, a precisão das previsões de longo prazo é relativamente reduzida devido à consideração de fatores mais complexos nesta previsão (Wu et al., 2022). A Classificação da previsão de geração de energia FV com base no horizonte temporal é resumida na Tabela 2.1.

Tabela 2.1 – classificação resumida do horizonte de previsão de energia FV.

Horizonte de previsão	Tempo/Período	Aplicação
Muito curto prazo	< 1 min	Controlando a distribuição de energia
Curto prazo	1 – Muitas horas	Garante o cumprimento, agendamento e despacho
Médio prazo	1 – Semana – 1 mês	Facilita o planeamento do sistema de energia e cronograma de manutenção
Longo prazo	1 – Mês – 1 ano	Útil para produção de energia e transmissão

2.4.6 Previsão Determinística ou Probabilística

Os métodos para prever a produção de energia FV podem ser divididos em determinísticos ou probabilísticos. Na abordagem probabilística, busca-se aproximar a probabilidade de todos os potenciais resultados da produção de energia FV, enquanto na abordagem determinística, faz-se uma previsão direta da produção futura de energia FV, sem levar em conta as incertezas da previsão. O primeiro método gera uma estimativa clara da previsão de produção de energia solar fotovoltaica e inclui a margem de erro associada à previsão. Ele fornece detalhes mais abrangentes sobre a previsão em comparação com o método determinístico. Já os segundos métodos carecem da capacidade de lidar com os parâmetros de incerteza do processo de previsão (Bazonis et al., 2023; El Hendouzi & Bourouhou, 2020; Iheanetu, 2022).

2.4.7 Previsão Fotovoltaica de Central Única e Regional

A produção de energia elétrica produzida por múltiplas centrais ou estações de energia solar FV pode ser agrupada para formar uma rede regional. Quando um modelo de previsão é desenvolvido para estimar a produção de energia FV de uma única estação, isso é considerado uma previsão de energia de uma única instalação ou estação. A previsão de produção de FV regional ocorre quando a previsão é feita para um conjunto de estações dentro da mesma região ou área administrativa (Iheanetu, 2022).

Foram estudadas três formas de previsão regional de saída FV:

- O somatório dos resultados que foram obtidos durante as previsões dos modelos locais das estações que compõem a região ou a área para efetuar a previsão;
- Aprimoramento estatístico ampliado da previsão das instalações (ou estações) individuais que fazem parte da região;
- São utilizados dados históricos agregados das estações individuais que fazem parte da região para realizar a modelagem da potência de saída da energia FV.

Em resumo, a previsão da produção de energia fotovoltaica em uma região envolve a soma dos resultados das estações individuais, ajustes estatísticos para maior precisão e modelagem de dados combinados para identificar padrões, que resultam em estimativas mais robustas.

2.5 Casos de Estudos

Nesta subsecção, são apresentados estudos relacionados aos métodos de previsão de energia fotovoltaica discutidos neste trabalho, nos quais suas aplicações foram testadas em diversas situações e contextos. Portanto, serão examinadas algumas pesquisas realizadas sobre a implementação desses sistemas de previsão de produção de energia fotovoltaica.

No estudo conduzido por Mathiesen & Kleissl, (2011), foi introduzido um modelo de aprimoramento da IGH, empregando três modelos diferentes para previsão meteorológica do tempo nos Estados Unidos. Os modelos NAM, GFS e ECMWF foram analisados com base em dados de medição de solo da rede de orçamento de radiação da superfície (SURFRAD), previsões de persistência e de céu limpo também foram validadas o que assegurou a credibilidade da pesquisa.

As previsões foram analisadas com RMSE e MBE, usando modelo estatístico de saída (MOS) para reduzir as métricas de MBE na estimativa da IGH. MBE foi calculado para cada modelo NWP baseado em uma função do ângulo zenital (SZA) e índice de céu limpo previsto (k_c), permitindo derivar uma função de correção via MOS. A aplicação de MOS, com base em SZA e k_c , resultou numa diminuição significativa do RMSE: $20,1 W/m^2$, $17 W/m^2$, e $25,6 W/m^2$, para os modelos NAM, ECMWF e GFS, respectivamente, eliminando eficientemente MBE.

A previsão NWP, combinada com o MOS baseado em SZA e k_c , oferece uma precisão essencial para avaliar outros métodos de previsão. De acordo com a análise, o MOS mostrou-se eficaz na redução do MBE em todos os modelos NWP. Dessa forma, a previsão mais precisa da radiação solar foi alcançada pelo GFS ajustado pelo MOS, apresentando um RMSE de $85 W/m^2$, seguido pelo ECMWF e pelo NAM. O ECMWF forneceu as estimativas mais precisas para condições de céu nublado, enquanto o GFS destacou-se para condições de céu limpo.

No estudo realizado por Fernandez-Jimenez et al., (2012), foi apresentado um modelo de previsão de curto prazo para uma central FV real conectada à rede elétrica. O modelo proposto consiste em três módulos, sendo dois baseados em modelos NWP e um baseado em ANN. O primeiro modelo é o NWP global do GFS, desenvolvido pelo centro nacional de revisão Ambiental (NCEP). Os dados provenientes do GFS são utilizados como dados de entradas para o segundo modelo NWP, mas com uma resolução temporal e espacial superior à do GFS. Este segundo modelo se refere ao modelo MM5, que fornece previsões para os parâmetros meteorológicos selecionados. Essas previsões são então utilizadas como entradas para o terceiro modelo, o qual é específico para a previsão da geração de energia elétrica por hora.

Os resultados observados foram utilizados como entradas em modelos de previsão como ANN, K-NN, ARIMA e sistemas ANFIS. O modelo MLP-ANN destacou-se como o mais eficaz dentre os demais. O RMSE para a capacidade nominal da central fotovoltaica é de 11,79% nos horizontes de previsão de 16 e 39 horas.

Em Alonso-Montesinos et al., (2015), foi desenvolvido um modelo de previsão para um horizonte de curto e médio prazo, abrangendo um intervalo de 1 a 180 minutos, em várias condições atmosféricas, como céu limpo, nublado e parcialmente nublado, utilizando uma câmara total sky imagery TSI 880. Os valores dos pixels na imagem digital foram convertidos para os espaços de cores HSV (matiz-saturação-valor) e RGB (vermelho-verde-azul). Em seguida, utilizou-se o movimento das nuvens para prever a posição futura dos pixels de irradiância e estimar os valores futuros de irradiância, aplicando a técnica de máxima correlação.

Os resultados revelaram que os valores do nRMSE para a irradiância direta normalizada (IDN) foram de 25,44%, para a irradiância difusa (ID) foram de 11,6%, e para a irradiância global horizontal (IGH) foram de 11,17%.

Durante toda a investigação, os resultados mantiveram-se estáveis ao longo de todo o período de observação, independentemente das condições atmosféricas. A metodologia proposta destaca que câmaras do céu podem proporcionar maior exatidão do que imagens de satélite em dias com nebulosidade, alcançando resultados positivos para a radiação direta e difusa.

Marquez et al., (2013) conduziram um estudo no Vale de San Joaquín, nas localidades de (Davis e Merced), onde propuseram um modelo híbrido que combina informações de imagens de satélite com ANN para previsão da IGH em horizontes temporais de 30, 60, 90 e 120 minutos. Os índices de cobertura de nuvens foram empregues como dados de entrada para o modelo ANN. Estas variáveis correspondem a técnicas que utilizam algoritmos de classificação de nuvens e velocimetria a partir de imagens de satélite. O modelo de persistência foi criado com base no índice atual de céu limpo para prever o índice futuro de céu limpo, o que é utilizado como métrica para avaliar a precisão das metodologias desenvolvidas.

O modelo de previsão foi analisado quanto ao seu desempenho utilizando métricas como MBE, MSE e RMSE. Os resultados indicaram que a abordagem proposta superou o modelo de persistência em aproximadamente 5-19% para previsões de curto prazo e 10-25% para previsões de longo prazo.

D. Yang et al., (2012), foi elaborada uma previsão horária da irradiância solar utilizando técnicas de análise de séries temporais, considerando os impactos da cobertura de nuvens. Três métodos distintos foram desenvolvidos, cada um utilizou diferentes conjuntos de dados meteorológicos como variáveis de entrada. O primeiro método usou dados horários de irradiância global horizontal (IGH), que foram decompostos em três componentes aditivas: sazonal,

irregular e de tendência. As componentes de tendência e irregularidade serviram como entradas para prever o IGH da hora seguinte, recorrendo ao modelo ARIMA.

O modelo ARIMA destacou-se pela sua flexibilidade e superioridade em comparação com outros modelos tradicionais, devido à sua capacidade de lidar com variações sazonais, erros aleatórios e valores atípicos. Além disso, consegue remover todas as Autocorrelações dos resíduos do modelo. Uma análise adicional foi feita sobre a irradiância direta normal (IDN) e a irradiância difusa (ID), de forma isolada, utilizando um método de decomposição para estimar o IGH. A terceira estratégia focou-se em avaliar o efeito da cobertura de nuvens através do modelo ARIMA, para antecipar alterações nessa cobertura.

Essas três abordagens foram aplicadas com dados de duas estações meteorológicas localizadas em Orlando e Miami, nos Estados Unidos. O terceiro modelo apresentou o melhor desempenho, com os menores desvios médios (MBE), que registou 0,39 para Miami e -0,27 para Orlando. Quanto aos erros quadráticos médios (RMSE), os valores foram de 29,73 para Miami e 32,80 para Orlando. Com isso, verificou-se que a inclusão de dados sobre a cobertura de nuvens, como feito no terceiro modelo, melhorou significativamente a precisão das previsões, especialmente em situações com medições limitadas de radiação solar.

Em Agoua et al., (2018), foi elaborado um modelo espaço-temporal para previsão de energia de uma central FV, abrangendo um intervalo de previsão que varia de minutos até 6 horas. Este método utilizou dois conjuntos de dados distintos, de forma a representar diferentes condições climáticas e densidades de instalação das centrais FV. Para enfrentar o problema da não estacionaridade nas séries de produção, implementou-se um procedimento de estacionarização, o que levou a uma redução considerável nos erros de previsão quando comparado ao uso de dados não processados. Além disso, o modelo utilizou a técnica de seleção de variáveis Lasso para lidar com a complexidade dos dados. A adição de variáveis meteorológicas, como a velocidade do vento, também contribuiu para aprimorar a precisão das previsões, que resultou em uma redução de 20% ou mais no nRMSE em comparação com métodos anteriores.

No estudo apresentado Chen et al., (2013), foram propostas duas redes neuronais artificiais, denominadas ANN-1 e ANN-2, com o objetivo de prever a produção de energia solar por módulos FV de Si-Policristalinos de 50 Wp. A irradiância solar e temperatura do ar foram utilizadas como variáveis de entrada. O modelo ANN-1 foi desenvolvido especificamente para prever a energia solar FV em condições nubladas, onde a irradiância solar média diária é igual ou inferior a 400 W/m^2 . Foi utilizado o software *MATLAB* para testar e auxiliar na implementação dos modelos. Ao analisar os resultados das métricas ao longo dos dias, observa-se que o modelo ANN-2 destaca-se notavelmente, apresentando valores de MBE entre 0,94% e 0,98% e um RMSE que se mantém abaixo de 0,2%. Em comparação com outras aborda-

gens, como o modelo de d odo, regress o anal tica, polinomial e linear m ltipla, os modelos ANN revelaram o menor MRE, com 2,5% em dias nublados e 2,3% em dias claros.

Em Notton et al., (2013), foi apresentado um estudo realizado na regi o de Ajaccio localizada na Fran a, onde foi proposto um m todo de tr s modelos baseados em ANN para prever a radia o solar num plano inclinado. Realizou-se a previs o da radia o solar com base em dados de radia o solar coletados a cada 10 minutos ao longo de um per odo de 5 anos. Para os dois primeiros modelos, escolheram-se cinco par metros de entrada:  ngulo zenital, tempo, declina o solar, irradi ncia extraterrestre horizontal de 10 minutos e irradi ncia global horizontal de 10 minutos. No entanto, foi introduzido um par metro adicional no terceiro modelo, nomeadamente o  ngulo de inclina o. Os resultados mostram que a exclus o de um par metro resulta numa melhoria de cerca de 9% no RMSE e de aproximadamente 5,5% no Erro M dio Absoluto Relativo RMAE.

Nespoli et al., (2018) desenvolveram um modelo de previs o de energia solar fotovoltaica utilizando ANN para melhorar a pot ncia de sa da esperada. O estudo foi conduzido em m dulos fotovoltaicos instalados no telhado do departamento de Energia do Polit cnico de Mil o, usando dados hist ricos de previs o meteorol gica coletados  s 11h e 23h para prever 12 e 24 horas   frente. Os dados foram divididos em conjuntos de treino (2014) e valida o (2017). Al m das vari veis tradicionais como temperatura e irradi ncia, eles incorporaram dados de radia o estimada por um modelo de c u limpo (CSR), para melhorar a precis o da previs o.

Os resultados mostraram que a tecnologia baseada em redes neuronais reduziu as imprecis es na previs o da pot ncia fotovoltaica, mas varia es significativas nas vari veis afetaram os resultados. Conclu ram que, em 2017, 40% das amostras mostraram uma pot ncia prevista superior   medida, e 75% indicaram radia o prevista maior que a m dia medida. A previs o mais precisa ocorreu em 17 de maio, enquanto a menos precisa foi em 11 de janeiro.

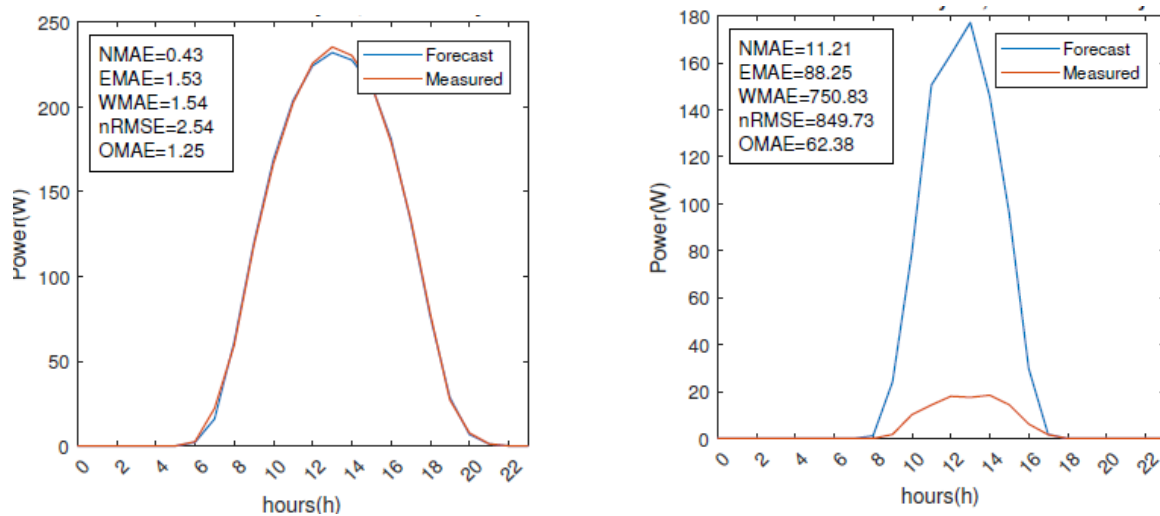


Figura 2.12 – Gráficos que ilustram a representação da produção FV nos meses de maio e janeiro respectivamente (Nespoli et al., 2018).

As linhas azuis mostram as estimativas de potência produzida, ao passo que as linhas vermelhas representam as medições reais de potência gerada usadas para comparação dos resultados.

O estudo conduzido por Mohanty & Kumar Patra (2015) em Greater Noida, Índia, focou-se no desenvolvimento de um modelo para prever a radiação solar global. Os autores sugeriram utilizar variáveis como a duração da luz solar, temperatura, humidade e outros fatores relevantes como parâmetros de entrada. O modelo proposto baseou-se em redes neurais artificiais recorrentes, especificamente no modelo autorregressivo não linear com entradas exógenas (NARX). O desenvolvimento e teste do modelo foram realizados através do software *MATLAB*. Os dados usados para o treino da rede cobriram o período de 2002 a 2005, enquanto os dados de teste referiram-se ao ano de 2006. Após a preparação inicial dos dados e o treino da rede neuronal, a análise dos resultados, nomeadamente o menor erro quadrático médio (MSE) e o coeficiente de regressão mais elevado, demonstrou que o algoritmo de Marquardt-Levenberg foi o mais eficaz para prever a radiação solar.

Em Shi et al., (2012), foram realizadas previsões da geração de energia FV para o dia seguinte utilizando SVM e características derivadas da classificação do clima em uma estação de energia FV na China. O modelo baseou-se em dados históricos organizados em quatro tipos de condições meteorológicas: céu coberto, dias ensolarados, períodos chuvosos e situações nebulosas. Cada modelo recebeu como entrada os dados de produção de energia FV histórica em intervalos de 15 minutos do dia mais próximo com condições similares, juntamente com as previsões das temperaturas média, mínima e máxima para o próximo dia conforme um relatório meteorológico local.

Como resultado, o modelo destinado a condições de tempo ensolarado mostrou-se superior aos outros na previsão da potência FV. No modelo desenvolvido, os erros médios de pre-

visão, RMSE e MRE, foram registrados como 2,10 MW e 8,64%, respectivamente. Assim, os sistemas propostos de produção de energia FV (GCPV) demonstram eficácia no desempenho.

Em Ekici (2014), foi proposta a estimativa diária da irradiação solar para o dia seguinte em Elazig, Turquia, utilizando uma Máquina de Vetores de Suporte com Mínimos Quadrados - LS-SVM e Função de Kernel RBF. Os dados de entrada abrangeram a temperatura média diária, temperatura máxima, duração do sol e irradiação solar do dia anterior. A simulação do modelo sugerido foi conduzida utilizando a SVM Toolbox do *MATLAB*, e foram avaliados seus resultados por meio de métricas de desempenho como RMSE, RME, MEF, Fração Absoluta de Variância e CVRMSE. O modelo mostrou ser eficaz e viável na previsão da radiação solar com base em dados meteorológicos históricos.

No estudo realizado por Ramli et al., (2015) na Arábia Saudita, em Jeddah e Quassim, foi proposto um modelo de previsão de radiação solar em superfícies de painéis solares fotovoltaicos com ângulos de inclinação específicos. O estudo utilizou métodos SVM e ANN para desenvolver este modelo. Para prever a radiação solar, foram utilizados dados sobre radiação solar direta, difusa e global na superfície horizontal. O desempenho dos modelos criados foi analisado e comparado através de diversas métricas, incluindo RMSE, Coeficiente de Correlação (R), Erro Médio Relativo (MRE) e tempo de processamento. Os resultados indicaram que o SVM obteve valores de MRE de 0,33 e 0,51, enquanto o ANN apresentou 0,19 e 1,16, respectivamente.

No estudo conduzido por Ma & Zhang (2022), foi proposto um modelo de previsão de curto prazo baseado na rede neuronal Elman, visando a previsão da potência FV. Inicialmente, emprega-se o algoritmo de média K-means para agrupar os tipos de clima e, para decompor a potência de saída FV nos diversos dados obtidos por esse agrupamento, utiliza-se o EEDM. Depois, cada parte da decomposição é alimentada na rede neuronal Elman, que foi otimizada com MFA, para prever a potência de saída de energia solar fotovoltaica. Esta abordagem ajuda a resolver problemas relacionados com a aleatoriedade dos pesos iniciais e do limiar, além de melhorar a eficiência do processo de Treino da rede neuronal Elman. Os resultados da simulação revelaram que o modelo MFA-Elman apresenta menor erro de previsão, maior precisão e confiabilidade na previsão, além de uma velocidade de previsão mais rápida, o que satisfaz os requisitos de previsão de curto prazo da potência FV.

No trabalho conduzido por Dong et al., (2014) em Singapura, foram empregues imagens de satélite com uma resolução temporal de 1 hora e espacial de 1 km, fornecidas pela Agência Meteorológica do Japão (JMA). Este estudo introduziu um modelo híbrido destinado à previsão da radiação solar global para cada hora do dia. O modelo sugerido funciona em duas etapas principais: Inicialmente, realiza-se a análise das imagens de satélite, que converte o nível de cinza em refletância e temperatura utilizando o algoritmo de calibração MTSAT.

Posteriormente, aplica-se a técnica de suavização exponencial no espaço de estados (ESSS) para estimar o índice de cobertura de nuvens. Em seguida, este índice previsto é usado para estimar a radiação solar global horária, empregando uma rede neuronal perceptron multicamada (MLPNN). O estudo foca no período das 07:00 às 19:00, considerando as horas após o pôr do sol. Para validar o desempenho do modelo ESSS-ANN proposto, foram comparados com ele vários modelos de previsão independentes.

No estudo conduzido por Lim et al., (2022), foi desenvolvido um modelo híbrido que integra CNN e LSTM para prever de forma consistente a produção de energia. O modelo proposto foi treinado e testado utilizando dados de saída de energia fotovoltaica de uma central localizada em Busan, Coreia. O desempenho do modelo foi avaliado tanto quantitativamente quanto qualitativamente. Neste contexto, a CNN foi empregada para classificar as condições meteorológicas, enquanto a LSTM foi responsável por capturar os padrões de geração de energia associados a essas condições.

Os resultados para dias ensolarados indicaram que o modelo desenvolvido alcançou RMSE de 4,58, MAE de 34,00 e MAPE de 4,58. As distribuições residuais revelaram um desvio padrão de 38,25 com média de 34,00, validando a eficácia do modelo proposto nesse cenário. Para dias nublados, o modelo apresentou RMSE de 27,55, MAE de 17,13 e MAPE de 7,06. As distribuições residuais mostraram um desvio padrão de 27,42 com média de 17,13. É importante ressaltar que a natureza dos dados coletados e os valores de produção de energia podem variar conforme o fabricante do inversor.

No estudo desenvolvido por Azimi et al., (2016), foi introduzido um método híbrido para previsão de radiação solar, que combina análise de séries temporais, clustering avançado utilizando o algoritmo TB K-means, e redes neurais MLPNN. A complexidade dos dados solares impacta negativamente na precisão das redes neurais, mas esse efeito é mitigado pelo pré-processamento dos dados por meio de séries temporais. O TB K-means agrupa os dados em clusters para melhorar a detecção de anomalias e padrões irregulares, selecionando o cluster ideal para entrada na MLPNN com base na proximidade temporal. Resultados mostraram que o TB K-means supera outras variantes do K-means e o método SOM, melhorando a precisão e velocidade de processamento da previsão. Em comparação com seis modelos estabelecidos e métodos de benchmark, o modelo híbrido proposto demonstrou a maior precisão na previsão de radiação solar.

Um novo método híbrido, SVM-WT, que combina Máquina de Vetores de Suporte (SVM) com Transformada Wavelet (WT) foi desenvolvido por Mohammadi et al., (2015). O modelo proposto foi desenvolvido para prever a IGH em escalas diárias e mensais para uma cidade costeira no Irã. O método foi confrontado com outras abordagens existentes, utilizando três conjuntos variados de parâmetros como entrada para estabelecer modelos distintos. Os

resultados indicam que o modelo SVM-WT, ao incorporar variáveis como duração relativa de insolação, diferença de temperaturas do ar, humidade relativa, temperatura média e radiação solar extraterrestre, apresentou o desempenho mais eficaz.

Comparado com outras abordagens disponíveis, o SVM-WT demonstrou eficácia superior segundo análises estatísticas. Para previsões diárias, o modelo alcançou um erro médio absoluto percentual de 6,9%, um viés absoluto médio de 0,84 MJ/m² e uma raiz quadrada do erro médio quadrático de 1,42 MJ/m², entre outros parâmetros avaliados. Em previsões mensais, os resultados foram ainda mais satisfatórios: erro médio absoluto percentual de 3,26%, viés absoluto médio de 0,51 MJ/m², raiz quadrada do erro médio quadrático de 0,67 MJ/m² e um coeficiente de determinação de 0,97. Adicionalmente, 88,70% das previsões diárias realizadas pelo melhor modelo SVM-WT estavam dentro da faixa aceitável de erro percentual relativo de -10% a +10%.

No artigo apresentado por Gairaa et al., (2016), foi introduzido um modelo híbrido que combina o modelo ARMA com o modelo ANN para a previsão da radiação solar global diária. Os dados foram coletados de duas estações meteorológicas localizadas em climas distintos na Argélia. Esta abordagem foi destacada por sua capacidade de aproveitar as particularidades e as vantagens únicas de ambos os modelos na captura de diversos padrões de comportamento. Antes de aplicar a modelagem ARMA e ANN, a radiação solar global foi transformada em um índice de clareza para garantir a estacionaridade dos dados. A partir desses dados estacionários, foram elaborados os modelos ARMA e ANN com o melhor desempenho. A seleção dos modelos ARMA (4,0) e ARMA (2,0) foi feita com base na análise das funções de autocorrelação (ACF) e autocorrelação parcial (PACF), além do critério AIC, como os mais adequados.

Os índices estatísticos (MBE, nMBE, RMSE, nRMSE, MPE, R²) indicaram que a abordagem integrada oferece maior precisão em comparação com os métodos ARMA e ANN utilizados separadamente. Observou-se uma melhoria significativa no modelo combinado em relação ao ARMA: o MBE diminuiu em 27,26%, o RMSE em 18,1% e o MPE em 1,39%. Em relação ao ANN, o nMBE reduziu em 2,7%, o nRMSE em 1,39% e o R² aumentou. A análise dos valores observados em contraste com os estimados por diversos métodos indica que o modelo integrado se destaca por oferecer um ajuste mais preciso aos dados experimentais.

A Tabela 2.2 descreve o resumo dos principais elementos de cada estudo, incluindo o tipo de método utilizado, a localidade onde o estudo foi conduzido, as variáveis de entrada utilizadas e as métricas de desempenho relatadas nos estudos.

Tabela 2.2 – Resumo dos casos de estudos onde foram aplicados alguns métodos de previsão.

Referência	Tipo de Modelo	Localidade	Variável de Entrada	Métrica e Resultados
Mathiesen & Kleissl, (2011)	NWP (NAM, GFS, ECMWF)	EUA	Dados SURFRAD, Previsões, MOS baseado em SZA e kc	RMSE: 20,1 W/m ² (NAM), 17 W/m ² (ECMWF), 25,6 W/m ² (GFS). MBE eliminado com MOS, RMSE final: 85 W/m ² (GFS), resultados variam conforme condições meteorológicas
Fernandez-Jimenez et al., (2012)	NWP, ANN	Central FV (não especificado)	Dados do GFS, MM5 e parâmetros meteorológicos	RMSE: 11,79% para central FV nos horizontes de previsão de 16 e 39 horas
Alonso-Montesinos et al., (2015)	total sky imagery (TSI 880)	Não especificado	Imagens digitais convertidas para RGB e HSV, movimento das nuvens	nRMSE: 25,44% (IDN), 11,6% (ID), 11,17% (IGH), resultados consistentes em diversas condições atmosféricas
Marquez et al., (2013)	Imagens de satélite + ANN	Vale de San Joaquín (Davis e Merced)	Índices de cobertura de nuvens, Imagens de satélite	Superou modelo de persistência em 5-19% para previsões de curto prazo e 10-25% para previsões de longo prazo
D. Yang et al., (2012)	ARIMA	Orlando e Miami, EUA	IGH, IDN, ID, cobertura de nuvens	MBE: 0,39 (Miami), -0,27 (Orlando), RMSE: 29,73 (Miami), 32,80 (Orlando), melhora ao incorporar cobertura de nuvens
(Agoua et al., 2018)	Séries Temporais	Não especificado	Dados meteorológicos e de produção FV	Redução de 20% ou mais no nRMSE comparado com métodos anteriores após estacionarização e seleção de variáveis
Chen et al., (2013)	ANN (ANN-1 e ANN-2)	Não especificado	Irradiância solar e temperatura do ar	MBE: 0,94% 0,98%, RMSE: 0,2%, MRE: 2,5% (dias nublados), 2,3% (dias ensolarados)

Notton et al., (2013),	ANN	Ajaccio, França	Ângulo zenital, tempo, declinação solar, irradiância extraterrestre horizontal e global (10 min)	Melhoria de 9% no RMSE e 5,5% no RMAE ao excluir um parâmetro
(Nespoli et al., 2018)	ANN	Milão, Itália	Temperatura, irradiância, radiação estimada por modelo de céu limpo	Resultados variaram, mas indicaram maior precisão em algumas condições, com previsão mais precisa em 17 de maio e menos precisa em 11 de janeiro
(Mohanty & Kumar Patra, 2015)	Redes neurais artificiais recorrentes (NARX)	Greater Noida, Índia	Duração da luz solar, temperatura, humidade	Marquardt-Levenberg foi o algoritmo mais eficaz, com MSE mais baixo e coeficiente de regressão mais elevado
(Shi et al., 2012)	SVM	China	Produção histórica de energia FV, previsões de temperatura média, mínima e máxima	RMSE: 2,10 MW, MRE: 8,64%, modelo mais eficaz para condições de tempo ensolarado
(Ekici, 2014)	LS-SVM	Elazig, Turquia	Temperatura média diária, máxima, duração do sol, irradiação solar do dia anterior	Eficaz e viável na previsão da radiação solar com base em dados meteorológicos históricos
(Ramli et al., 2015)	SVM e ANN	Jeddah e Quassim, Arábia Saudita	Radiação solar direta, difusa e global na superfície horizontal	MRE: 0,33 e 0,51 SVM, 0,19 e 1,16 ANN, SVM e ANN comparados utilizando métricas como RMSE, CC, MRE
Ma & Zhang (2022),	Redes neuronais Elman	Não especificado	Dados climáticos agrupados pelo algoritmo K-means	Modelo MFA-Elman apresentou menor erro de previsão, maior precisão e confiabilidade na previsão
Dong et al., (2014)	ESSS-ANN)	Singapura	Imagens de satélite, nível de cinza convertido em refletância e temperatura	Modelo ESSS-ANN proposto comparado com modelos de previsão independentes, melhora em precisão de radiação solar global
(Lim et al., 2022)	CNN e LSTM	Busan, Coreia	Dados de saída de ener-	RMSE: 4,58 (dias

			gia fotovoltaica, condições meteorológicas	ensolarados), 27,55 (dias nublados), MAE e MAPE variaram conforme condições meteorológicas
(Azimi et al., 2016)	Modelo híbrido (séries temporais + TB K-means + MLPNN)	Não especificado	Dados solares e meteorológicos agrupados em clusters	Melhor precisão na previsão de radiação solar comparado com seis modelos estabelecidos e métodos de benchmark
(Mohammadi et al., 2015)	SVM-WT	Cidade costeira no Irã	Duração relativa de insolação, diferença de temperaturas do ar, humidade relativa, temperatura média	Erro médio absoluto percentual: 6,9996% (diárias), 3,2601% (mensais), SVM-WT apresentou desempenho superior segundo análises estatísticas
(Gairaa et al., 2016)	Modelo híbrido (ARMA + ANN)	Argélia	Índice de clareza, dados meteorológicos de estações distintas	MBE diminuiu em 27,26%, RMSE em 18,1%, MPE em 1,39% comparado com ARMA, nMBE reduziu em 2,7%, nRMSE em 1,39%, R2 aumentou em relação ao ANN, modelo combinado superior

Os estudos revisados mostram avanços significativos nos métodos de previsão de produção de energia solar fotovoltaica. Destacam o uso de dados meteorológicos, modelos de aprendizado de máquina e análise de dados históricos para melhorar as previsões. É enfatizada a importância de variáveis como irradiância solar, temperatura, sazonalidade e características climáticas regionais. Há uma tendência crescente de usar técnicas avançadas de inteligência artificial para lidar com a complexidade dos dados, que visa aumentar a precisão das previsões. Em resumo, os estudos refletem esforços contínuos para aprimorar a eficiência e a confiabilidade das previsões, apoiando a integração da energia solar no sistema elétrico.

MÉTODOS DE PREVISÃO DE ENERGIA SOLAR FOTOVOLTAICA

Neste capítulo, serão apresentados em detalhe os métodos de previsão da produção de energia solar fotovoltaica abordados anteriormente. Será feita uma descrição pormenorizada de todos os métodos, sejam eles físicos, estatísticos ou híbridos, permitindo uma compreensão aprofundada das diferentes abordagens utilizadas para prever a produção de energia fotovoltaica. Adicionalmente, será realizada uma comparação entre os principais métodos discutidos, salientando tanto as suas vantagens como as suas limitações.

3.1 Método de Previsão Numérica de Tempo

As previsões meteorológicas são essenciais como ponto inicial para o desenvolvimento dos modelos de previsão, uma vez que estão diretamente associadas à produção de energia FV (Sobri et al., 2018). Reduzir os erros nas variáveis meteorológicas previstas diminui a margem de erro final da previsão, aumentando sua precisão e aproximando-a do valor real. Essa previsão é realizada por meio de técnicas computacionais, como exemplificado pelo modelo NWP que combina informações meteorológicas e equações de modelos atmosféricos para gerar previsões (R. Ahmed et al., 2020).

Este método é geralmente dividido em duas categorias, consoante a escala: modelos de mesoescala e modelos globais. O modelo de mesoescala concentra-se nas características atmosféricas de zonas específicas, como regiões ou países, enquanto o modelo global analisa a atmosfera em uma escala mais ampla, cobrindo todo o planeta (Sobri et al., 2018).

Segundo R. Ahmed et al., (2020), existem aproximadamente 15 serviços meteorológicos que utilizam o modelo NWP global, incluindo o Global Forecast System (GFS), o Climate Forecast System (CFS) e o Global Data Assimilation System (GDAS). Todos esses servi-

ços são administrados por entidades governamentais, como a NOAA nos Estados Unidos e o Centro Europeu de Previsões Meteorológicas a Médio Prazo (ECMWF).

Os modelos NWP possuem a capacidade de antecipar as condições climáticas com mais de 15 dias de antecedência. Este processo é efetuado por meio de um conjunto de equações numéricas que modelam, ao mesmo tempo, o estado físico e as dinâmicas da atmosfera (R. Ahmed et al., 2020; Lorenz & Heinemann, 2012). Do ponto de vista matemático, a NWP pode ser expressa pela seguinte fórmula:

$$F(A) = \frac{\Delta A}{\Delta t} \quad (3.1)$$

Onde, a mudança no valor da resposta prevista em uma localização espacial específica é representada por ΔA ; a variação no tempo ou horizonte temporal é indicada por Δt ; e $F(A)$ engloba as variáveis que influenciam o valor de A . No entanto, no que diz respeito à previsão da potência de saída de sistemas FV, o modelo utiliza parâmetros meteorológicos específicos, tais como a IGH, humidade relativa, velocidade e direção do vento. A qualidade das previsões tende a ser superior quando as variáveis meteorológicas se mantêm estáveis. Por outro lado, previsões imprecisas podem surgir quando há alterações bruscas nos valores dessas variáveis.

3.2 Métodos Baseados na Previsão de Nuvens

A cobertura de nuvens é um dos principais fatores que influenciam a intensidade da radiação solar que atinge a superfície da Terra. A quantidade de energia solar que consegue penetrar através das nuvens não é uniforme; ela varia de acordo com o tipo e a densidade das nuvens. O movimento das nuvens, assim como seu surgimento, dissipação e deformação, provoca oscilações na intensidade da radiação solar, que causam impacto na produção de energia FV.

Segundo Mohammadi & Goudarzi (2018), para análises de nuvens, tem sido empregues dois métodos distintos: imagens de satélite e imagens do céu a partir do solo, conforme mostra a Figura 3.1.




Figura 3.1 – Representação dos métodos de imagem de satélite e imagem do céu (Rajagukguk et al., 2021).

3.2.1 Método de Imagem do Céu

O método imagem do céu (SI) é um método de previsão que consiste na utilização de uma câmara digital que captura imagens nítidas do céu de um extremo ao outro, sendo utilizada para identificar nuvens, calcular a altura das nuvens acima da superfície e rastrear o movimento das nuvens (H. Yang et al., 2014). A vantagem do SI reside na sua capacidade de fornecer detalhes minuciosos sobre a extensão, estrutura e movimento das nuvens presentes no momento da previsão. Essas informações possibilitam a criação de previsões de muito curto prazo sobre os padrões futuros de nuvens nas imediações da instalação de energia FV (Coimbra et al., 2013).

A previsão baseada em SI atinge um horizonte máximo de cerca de 30 minutos, determinado pelo comprimento da linha de visão dividido pelas velocidades típicas das nuvens, com a máxima precisão ocorrendo entre 5 a 10 minutos. Este processo envolve quatro etapas essenciais. Primeiramente, é imprescindível capturar uma imagem do céu nas redondezas do local onde se pretende realizar a previsão, o que permitirá identificar a presença de nuvens. Ao utilizar um equipamento que forneça imagens sequenciais da mesma área, é viável avaliar tanto o deslocamento quanto a velocidade das nuvens, sendo esses dados organizados em vetores de movimento. Por último, com a localização das nuvens e os vetores de movimento em mãos, é possível fazer previsões de curto prazo sobre a cobertura nublosa, a irradiância solar e a geração de energia fotovoltaica (Pelland et al., 2013).




Figura 3.2 – Etapas das previsões do método imagem do céu (Pelland et al., 2013).

3.2.2 Método de Imagem de Satélite

Os conceitos de captura de imagens por satélite são bastante semelhantes aos modelos de captura de imagens do céu. As formações de nuvens são identificadas a partir de imagens visuais e infravermelhas recolhidas por sensores em satélites que sobrevoam a região (Blanc et al., 2017). O modelo que utiliza vetores de movimento das nuvens, baseado em imagens de satélite, calcula a transmissividade a partir da luminosidade que a Terra emite e que passa pelas nuvens até chegar aos satélites. Assim, é viável avaliar a profundidade da nebulosidade e, através de imagens consecutivas, determinar os vetores de movimento das nuvens.




Figura 3.3 – Movimento das nuvens em métodos baseados em satélite (Serrano, 2020).

A principal vantagem em relação ao método anterior, reside no fato de que a área coberta por um satélite é significativamente mais ampla, abrangendo todo o planeta. Além disso, a qualidade das imagens obtidas por satélites é indiscutivelmente superior. Por esse motivo, as

imagens de satélite são vistas como a melhor abordagem para previsões com um horizonte temporal que vai de 1 minuto a 5 horas (Ineichen & Perez, 1999).

3.3 Método de Persistência

Frequentemente, o modelo de persistência é considerado uma abordagem estatística básica e padronizada. Por conseguinte, é comum utilizá-lo para avaliar a eficácia de outros modelos de previsão e comparar o seu desempenho. No modelo de persistência, pressupõe-se que o valor de saída de energia FV seja o mesmo à mesma hora do dia anterior ou do dia seguinte (Iheanetu, 2022). Por outras palavras, o princípio é de que o estado meteorológico do dia seguinte será idêntico ao do dia anterior, isto é, a radiação solar esperada para o dia seguinte é projetada para ser semelhante à do dia anterior (Dutta et al., 2017). Por exemplo, se o dia atual está com céu limpo e marcando 30°C, o modelo prevê que amanhã teremos novamente céu limpo e os termómetros a marcar 30°C. Assim, é possível calcular a IGH de forma instantânea ao decompor as informações da previsão de irradiância global horizontal em irradiância global horizontal de céu limpo e projetar o índice de céu limpo. No entanto, esse índice não leva em conta as flutuações do ângulo solar zenital devido as condições climáticas como nuvens, chuva, ou tempestades durante o período de previsão.

De acordo com Perez et al., (2010), Este método é amplamente aplicado em previsões a curto prazo, particularmente em previsões de uma hora de antecedência para a produção de energia FV e eólica. A precisão desse modelo é influenciada pela estabilidade do clima e, à medida que o horizonte de previsão se estende, os erros de previsão de potência também aumentam. Este método pode ser expresso matematicamente pela seguinte expressão (R. Ahmed et al., 2020):

$$P(t + k|t) = \frac{1}{T} \sum_{i=0}^{n=1} (P - i\Delta t) \quad (3.2)$$

Onde, k representa o período de tempo de previsão, e a potência prevista para o tempo $t + k$ no instante t é representado por $P(t + k|t)$. O intervalo de previsão é denotado por T , enquanto n representa a quantidade de medições históricas utilizadas. A potência real medida em t , $(P - i\Delta t)$, ao longo dos passos i dentro de T , onde Δt representa a diferença de tempo entre os passos da série temporal medida.

Este método utiliza ferramentas estatísticas para analisar diversas variáveis de entrada com o objetivo de prever a produção de energia FV. Nesse processo, são utilizados dados históricos de séries temporais, e é essencial que dados recentes sejam incluídos na análise para garantir maior precisão (Iheanetu, 2022).

3.4 Métodos Baseados em Séries Temporais

As séries temporais capturam informações em momentos sucessivos, fornecendo dados estatísticos que ajudam a prever o comportamento de uma variável medida. Esses dados são frequentemente coletados em intervalos regulares, que podem variar de mensais a diários, ou até mesmo por horas e minutos, conforme a frequência com que a variável muda ao longo do tempo. A análise dessas séries busca prever valores futuros ao estudar os padrões das informações passadas (Cornaro et al., 2015; Sobri et al., 2018).

Segundo Cornaro et al., (2015) os métodos baseados em séries temporais podem ser divididos em: Média móvel exponencial ponderada (EWMA), Média móvel autorregressiva (ARMA), Média móvel autorregressiva integrada (ARIMA) e Método de regressão.

3.4.1 Método de Média Móvel Exponencial Ponderada

O método de média móvel exponencialmente ponderada (A EWMA), também conhecido como suavização exponencial, é uma técnica singular que emprega uma função de janela exponencial para analisar dados históricos de séries temporais com o objetivo de fazer previsões. Este método dá maior peso aos dados mais recentes em comparação com os dados históricos mais antigos, onde os pesos atribuídos diminuem exponencialmente à medida que os dados se tornam mais antigos (Guleryuz, 2021). Contudo, este método pode rapidamente aprender e realizar conclusões a partir de suposições (Ostertagová & Ostertag, 2013).

De acordo com Sbrana & Silvestrini, (2014), Brown foi o primeiro a formular essa técnica que desde então tem sido extensivamente empregada. Holt fez uma ampliação do método em 1957, e Winter deu um passo adicional em 1960. Por esse motivo, ela é conhecida como método de Holt-Winter. Este método é expressa pela seguinte equação matemática:

$$\bar{X}_{l+1} = \alpha X_l + (1 - \alpha)\bar{X}_l = \bar{X}_l + \alpha(X_l - \bar{X}_l) \quad (3.3)$$

Onde, a constante de suavização, é representada por α , que pode ter qualquer valor entre 0 e 1. A EWMA requer um valor inicial que pode ser previsto ou assumido, tal como, por exemplo: $\bar{X}_{l+1} = \alpha X_l$. O modelo sugere que o valor previsto no tempo $l+1$ é determinado pela adição do último valor antecipado, \bar{X}_{l+1} , e do ajuste de erro na previsão, $\alpha(X_l - \bar{X}_l)$. Se existir uma tendência nos dados, a previsão EWMA será retardada.

3.4.2 Método de Média Móvel Autorregressiva

O modelo de média móvel autorregressiva (ARMA) é uma abordagem estatística comum em análises de séries temporais, que são frequentemente aplicadas em previsões. Diver-

os pesquisadores realizaram avaliações do modelo em várias aplicações de previsão, incluindo previsões solares e eólicas, onde têm demonstrado consistentemente uma precisão satisfatória (R. Ahmed et al., 2020). De acordo com Iheanetu, (2022) este método é formado pela combinação das técnicas autorregressivas (AR) e de média móvel (MA) para efetuar a previsão da saída FV a partir de dados históricos.

A técnica AR emprega a correlação entre dados históricos e dados em tempo real para calcular uma média ponderada dos dados anteriores, que visa prever os próprios valores futuros. No entanto, se o coeficiente de autocorrelação for inferior a 0,5, a precisão da previsão pode ficar comprometida. Por sua vez, o método MA consiste em calcular uma média ponderada dos erros aleatórios presentes no modelo AR. Estes erros aleatórios estão vinculados aos erros aleatórios gerados anteriormente, o que contribui para eliminar as flutuações aleatórias na previsão (Feng & Xu, 2021).

No método ARMA, os erros que não são considerados no método AR são incorporados ao método MA para realizar ajustes suplementar. Este método pode ser expresso pela seguinte fórmula matemática:

$$X(t) = \sum_{i=1}^p \alpha_i X(t - i) + \sum_{j=1}^q \beta_j e(t - j) \quad (3.4)$$

Onde, a potência solar prevista no tempo é representada por $X(t)$, p e q indicam o número de processo ou a ordem, ao passo que α_i e β_j representam os coeficientes dos modelos AR e MA, respectivamente. $e(t)$ é um ruído branco gerado aleatoriamente, é um componente não correlacionado com as previsões do modelo (Bazionis et al., 2023).

Na Figura 3.4, pode-se observar um diagrama que ilustra de forma geral o funcionamento do modelo de previsão baseado em ARMA.

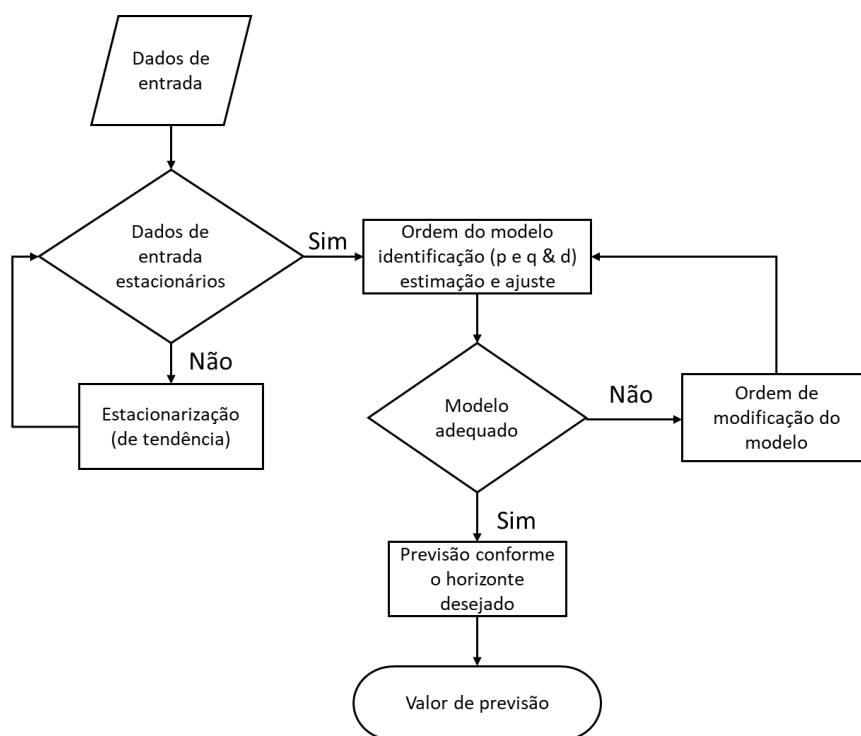


Figura 3.4 – Esquema geral de um modelo de previsão baseado no modelo ARMA (Sobri et al., 2018).

O ARMA mostra-se uma promissora ferramenta para prever e compreender valores futuros de séries temporais específicas, devido à sua habilidade em extrair informações estatísticas cruciais durante o processo de previsão. A flexibilidade é outra vantagem significativa dos modelos ARMA. Ao aplicar diversas ordens nos modelos AR e MA, o ARMA pode representar uma variedade de séries temporais (Bazionis et al., 2023). No entanto, a necessidade de séries temporais estacionárias representa uma grande desvantagem deste modelo.

3.4.3 Método Autorregressivo Integrado de Média Móvel

O método autorregressivo integrado de média móvel (ARIMA), frequentemente chamado de Box-Jenkins, foi criado por George Box e Gwilym Jenkins em 1976 (Haiges et al., 2017). Este modelo pode ser visto como uma versão aprimorada do ARMA, que incorpora um componente integrado que o torna mais eficiente. O modelo ARIMA é uma abordagem amplamente utilizada na análise de séries temporais, pois proporciona um padrão de precisão na previsão para horizontes de curto prazo. Além disso, este modelo consegue adaptar valores não estacionários dos dados observados. A estrutura deste modelo combina autoregressão (AR), integração (I) e média móvel (MA) para analisar e prever as propriedades das séries temporais (R. Ahmed et al., 2020).

Segundo Sobri et al., (2018) o modelo ARIMA é superior em flexibilidade e capacidade em relação aos outros modelos tradicionais, devido à sua habilidade eficaz para lidar com flutuações sazonais, erros imprevisíveis e valores discrepantes. Todas as correlações autoexis-

tentes podem ser eliminadas dos resíduos do modelo. De acordo com Ahmed et al., (2020), a fórmula do modelo ARIMA geralmente expressa como (p, d, q) para uma série temporal X1, X2, X3 é a seguinte:

$$\Phi_p(B)\Delta^d X_t = \theta_q(B)a_t \quad (3.5)$$

$$\Phi_p(B) = \phi_1 B - \phi_1 B^2 \dots \phi_p B^p \quad (3.6)$$

$$\theta_q(B) = \theta_1 B - \theta_2 B^2 \dots \theta_q B^q \quad (3.7)$$

Onde, B representa o deslocamento retroativo, $\Delta = 1 - B$ e $BX_y = X_{y-1}$ é diferença retroativa, Φ_p e Θ_p representam números polinomiais de ordem p e q respetivamente. O modelo ARIMA (p, d, q) resulta da combinação da parte autorregressiva (p), uma parte integradora $I(d) = \Delta^d$ e uma componente de médias móveis (q). As variáveis em Φ e Θ são cuidadosamente escolhidas para garantir que todos os polinómios tenham raízes fora do círculo unitário, evitando assim a geração de processos não-estacionários. Introduzem-se perturbações arbitrárias retiradas de uma distribuição com média zero e variância σ_a em a_t, a_{t-1}, a_{t-2} como parte do processo de ruído branco. Dessa forma, as propriedades intrínsecas da série temporal são compreendidas através do ruído branco e do operador de deslocamento retroativo (R. Ahmed et al., 2020).

Segundo Iheanetu, (2022), o modelo ARIMA pode ser aplicada de forma autónoma ou combinada com outros modelos de previsão para prever a potência gerada pelos sistemas FV. Utiliza-se a técnica de regressão para estabelecer uma ligação entre as variáveis explicativas (parâmetros meteorológicos) e as variáveis dependentes (previsão da potência de saída dos sistemas FV).

3.4.4 Método de Regressão

O método estatístico de regressão é empregue para analisar a ligação entre as variáveis dependentes e as variáveis explicativas, essenciais para prever os parâmetros meteorológicos da previsão de energia solar, como a potência FV (Bazionis et al., 2023). Este método é expresso pela seguinte expressão:

$$Y = F(X, \beta) \quad (3.8)$$

Onde, os parâmetros do modelo de regressão são representados por β , o Y representa o vetor das variáveis dependentes e X é a matriz das variáveis independentes explicativas incluídas.

Em um modelo de regressão múltipla, é possível incluir diversas variáveis explicativas, o que se mostra especialmente importante ao prever energia solar, como no caso da irradiação

solar. No entanto, a seleção aleatória de variáveis explicativas que parecem relevantes para a variável dependente pode resultar em baixa precisão e complicar a interpretação do modelo. Para superar esses desafios, é essencial realizar uma seleção criteriosa das variáveis explicativas, o que pode aprimorar a eficiência e a precisão do modelo.

3.5 Métodos Baseados em Aprendizagem de Máquina

A aprendizagem de máquina (ML) é uma abordagem inteligente para modelar padrões de dados, sejam lineares, não lineares ou não estacionários. No entanto, é importante destacar que esta técnica necessita de uma quantidade substancial de dados de entrada para melhorar a precisão do modelo (Iheanetu, 2022).

Nos últimos anos, as técnicas de ML têm ganhado destaque em diversos setores, especialmente em aqueles que lidam com grandes volumes de dados. Essas abordagens são multifacetadas, e integram conceitos de estatística, matemática, mineração de dados, otimização e inteligência artificial (AI). Independentemente da complexidade matemática envolvida, o objetivo do ML é estabelecer conexões significativas entre os dados de entrada e saída para resolver problemas variados de forma eficaz (Anuradha et al., 2021).

Segundo Akhter et al., (2019), os métodos baseados em ML podem ser divididos em três tipos principais: rede neuronal artificial, máquinas de vetores de suporte e máquinas de aprendizagem extrema. A seguir, será feita uma análise dessas três abordagens.

3.5.1 Rede Neuronal Artificial

A rede neuronal artificial é um modelo estatístico amplamente utilizado e eficaz, sendo considerado o algoritmo mais popular para a previsão e modelagem da potência de saída de sistemas FV. Este método é tido como um sistema de AI que se inspira no funcionamento do cérebro humano (Jamil et al., 2023). As ANN são estruturas compostas por camadas interligadas de nós ou neurónios que processam informações para gerar saídas. Um tipo mais simples de ANN é o de camada única (Feedforward), é composta por uma camada de entrada, uma ou mais camadas ocultas para análises de dados, e uma camada de saída que completa o processamento dos dados para fornecer a saída da rede, como ilustra a Figura 3.5. Cada camada contém neurónios que se ligam aos neurónios das camadas vizinhas através de pesos que regulam a intensidade das conexões e, durante o Treino da rede neuronal, esses pesos são ajustados para otimizar o processo de aprendizagem (Ledmaoui et al., 2023).

As ANN são altamente adaptáveis, sendo capazes de desempenhar funções como regressão, ajuste de curvas e previsão. Assim como o cérebro humano, elas adquirem e retêm conhecimento por meio dos pesos sinápticos. As pesquisas sobre ANN investigam o funcio-

namento cerebral com o intuito de desenvolver aplicações práticas futuras. Ao contrário dos métodos convencionais que dependem de algoritmos pré-programados, as ANN aprendem a resolver problemas processando dados e produzindo resultados desejados. Elas têm o potencial de substituir o cérebro humano em tarefas computacionais avançadas, melhorando o desempenho e reduzindo erros (Jamil et al., 2023).




Figura 3.5 – Estrutura básica de uma rede neuronal artificial (Chu et al., 2015).

O elemento fundamental de uma ANN é o neurónio, que combina a saída através de uma função de transferência. Diversas camadas de neurónios são interligadas por pesos multiplicados para cada entrada, que funcionam como conectores entre a entrada e o neurónio. Na fase final do processo, o neurónio utiliza uma função de transferência para determinar o resultado. A saída de um neurónio resulta da soma ponderada das entradas, processadas por uma função de ativação como ilustra a Figura 3.6. Esta função de ativação introduz não linearidade ao modelo, permitindo-lhe aprender relações mais complexas entre as entradas e saídas.

De acordo com Hossain et al., (2017), entre as funções de ativação mais frequentemente utilizadas, destacam-se a linear, a base radial gaussiana, a sigmoide, a tangente hiperbólica, a função degrau unipolar e a função degrau bipolar, além das funções lineares unipolar e bipolar. Além das diferentes funções de ativação, as técnicas de previsão com ANN sofreram modificações significativas nas últimas décadas para se ajustarem a diferentes projeções de entrada-saída e várias arquiteturas. A fórmula matemática que expressa a ANN pode ser descrita como:

$$U_J = b + \sum_{K=1}^J (W_K + I_K) \quad (3.9)$$

Onde, U_J é a saída final da rede, b é o peso do viés, J , W_K e I_K são os números de entradas, peso de conexão e entrada da rede, respetivamente.

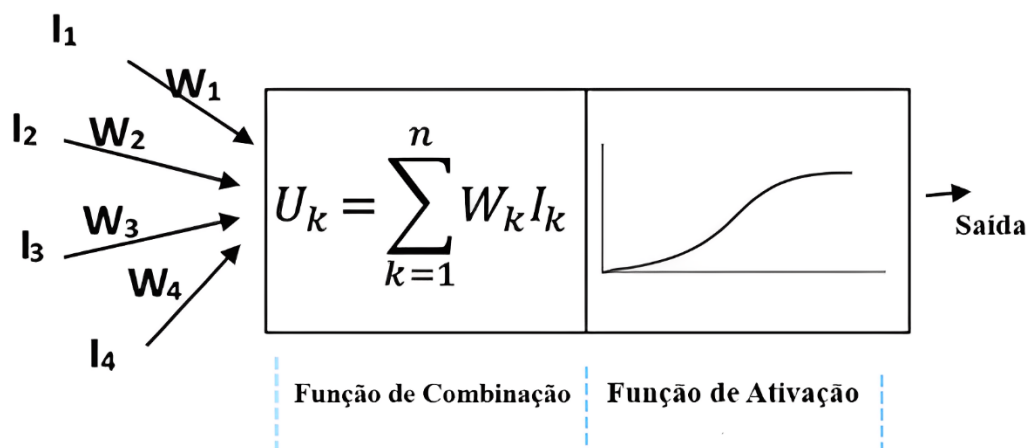


Figura 3.6 – Representação de um modelo matemático de uma ANN, adaptado de (Chu et al., 2015).

Segundo Sobri et al., (2018), a modelagem com ANN pode resolver a complexidade dos dados não lineares, a organização de dados, o reconhecimento de padrões, a simulação e a otimização. A precisão das previsões com modelos de ANN depende dos parâmetros de entrada, do algoritmo de treino e da estrutura configurada. A complexidade típica dos problemas práticos pode ser eficazmente abordada através da utilização de ANN para lidar com dados complexos e não lineares, sem pressupor previamente a natureza dessas correlações. O Treino é a fase mais crucial na implementação de ANN.

Conforme ilustra a Figura 3.7, a modelagem de uma ANN pode ser dividida em três estágios distintos, onde cada um desempenha um papel crucial no desenvolvimento e na eficácia do modelo. Os passos a seguir descrevem os estágios da modelagem da ANN:

- **Processo de design:** O processo de design consiste em escolher o tipo de ANN, determinar quantos neurónios estarão em cada camada, definir o número de camadas, especificar os parâmetros de entrada e saída, além de realizar o treino e validar os conjuntos de dados escolhidos.
- **Processo de Treino:** No processo de treino de uma ANN, a rede é ajustada através do algoritmo de aprendizagem usando uma parte dos dados de entrada. O algoritmo tenta encontrar uma relação de mapeamento ajustando os pesos sinápticos. Os erros são calculados comparando os resultados de saída com os dados esperados ou medidos. A magnitude dos erros é usada para atualizar os pesos e vieses, repetindo-se o processo até alcançar a precisão desejada.
- **Fase de validação:** Na fase de validação, o modelo ANN é testado com dados novos, que não foram utilizados durante o treino. Caso o teste de validação seja

bem-sucedido, o modelo estará pronto para a sua função designada. Caso contrário, poderá ser necessário realizar ajustes na fase de treino,

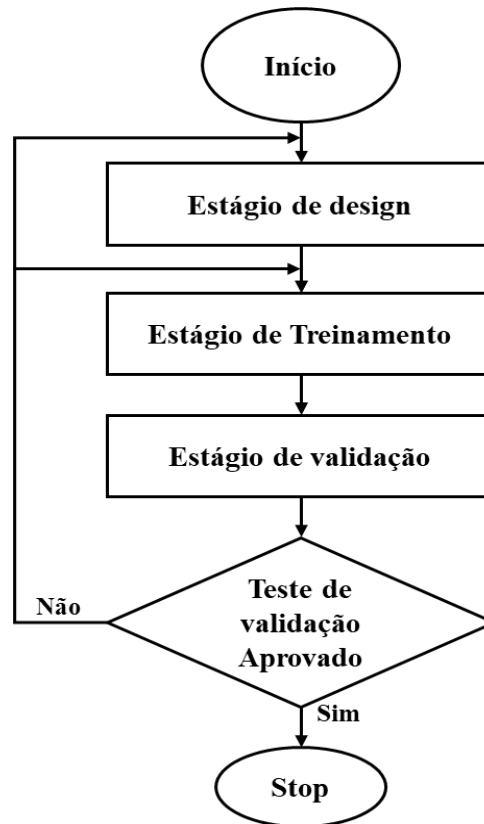


Figura 3.7 - Diagrama do processo de modelagem para ANN (Sobri et al., 2018).

Frequentemente, redes neurais de uma única camada têm sido utilizadas para resolver desafios de previsão de energia fotovoltaica. No entanto, essas redes enfrentam dificuldades intransponíveis ao lidar com padrões complexos e não lineares entre os conjuntos de dados de entrada e o resultado desejado. Como solução, foram desenvolvidas redes neurais de múltiplas camadas, com diversas arquiteturas e algoritmos de mapeamento de dados, especialmente projetadas para lidar com situações complexas que envolvem relações não lineares entre entrada e saída. Segundo Ahmed et al., (2020), algumas das principais ANN de múltiplas camadas comumente usadas são, redes neurais de percepção de múltiplas camadas (MLPNN), redes neurais recorrentes (RNN) e redes neurais de função de base radial (RBFNN). A seguir, serão detalhadas as principais ANN comumente usadas para previsões.

3.5.1.1 Rede Neuronal de Percepção de Múltiplas Camadas

A rede neuronal de percepção de múltiplas camadas, é uma ferramenta muito importante e eficiente quando se usa ANN para fazer previsões e classificações. Esta técnica é tão poderosa que consegue resolver problemas complicados através da aproximação universal e da modelação não linear, algo que uma ANN de camada única não consegue fazer. O MLP é

tipicamente composto por três ou mais camadas de nós que interagem entre si, como ilustra a Figura 3.8.




Figura 3.8 – Exemplo de uma estrutura de MLPNN adaptado de (Ahmed et al., 2020).

Como se pode observar na figura acima, cada camada de nós está ligada aos nós da camada seguinte através de pesos específicos. Dessa forma, o modelo consegue aprender a correlação entre as entradas e as saídas através de um processo de aprendizagem adequado. A relação entre o número de nós e a camada oculta desempenha um papel crucial nesse contexto (R. Ahmed et al., 2020; Akhter et al., 2019).

3.5.1.2 Redes Neurais Recorrentes

Redes neurais recorrentes, são redes que utilizam retroalimentação para processar dados. Essencialmente, isso implica que elas retêm memória do que ocorreu anteriormente e aplicam esse conhecimento para tomar decisões no presente. Em comparação com redes neurais Feedforward (FFNN), que apenas avançam sem considerar o passado, as RNN são mais complexas devido a essa capacidade de memória. Isso as torna mais adequadas para lidar com sistemas nos quais a sequência temporal é crucial, como previsões meteorológicas ou tradução de textos. Contudo, o treino de uma RNN pode ser mais demorado do que o de uma FFNN devido ao processamento adicional de informações que necessitam realizar (Rodríguez et al., 2021).

A Figura 3.9, mostra a estrutura básica de um modelo RNN, que consiste em um loop de retroalimentação interno, que lhe permite operar como um mecanismo de previsão. No funcionamento de uma RNN, a saída gerada por uma camada neuronal é incorporada ao próximo vetor de entrada e é reintegrada na mesma camada, a qual é a única camada que compõe todo o sistema (R. Ahmed et al., 2020).




Figura 3.9 – Estrutura básica de uma rede RNN adaptado de (R. Ahmed et al., 2020).

Cada neurônio ativo na RNN está interligado com todos os outros neurônios de processamento, incluindo-se a si próprio, o que significa que a saída da RNN é influenciada pelo feedback do passo de tempo anterior e pela entrada atual. A seguinte equação define a função de ativação de uma RNN, a qual é estabelecida pela combinação ponderada dos sinais de entrada e do feedback.

$$S_t(t) = \sum_{P=1}^{P+1} (W_{IK} X_P(t)) \sum_{q=1}^q V_{kq} Y_q(t) \quad (3.10)$$

Onde, a função de ativação $S_t(t)$ representa a ativação no tempo t do neurônio k , sendo V_{kq} o peso da conexão entre o neurônio q e o neurônio k , e $p + 1$ indica o valor do viés.

3.5.1.3 Rede Neuronal de Função de Base Radial

A rede neuronal de função de base radial (RBFNN) é conhecida por ser consideravelmente mais veloz e eficaz do que outras técnicas de ANN (Akhter et al., 2019). Essas vantagens fazem com que este modelo seja extensivamente utilizado em diversas áreas, como aproximação, previsão de séries temporais, classificação e controle de sistemas. A estrutura da RBFNN utiliza funções de base radial para desempenhar o papel de funções de ativação. Este tipo de rede normalmente consiste em duas camadas. As características são incorporadas na primeira camada através da função de ativação de base radial e, em seguida, a saída desta camada é usada para calcular a saída correspondente no passo de tempo seguinte. Os pesos sinápticos distinguem ambas as camadas. Na camada inicial, o valor ponderado origina-se das informações de entrada, enquanto o cálculo determina o peso da camada subsequente. A

RBFNN pode aprender usando métodos não supervisionados, visto que apenas dados de entrada são inseridos na rede (R. Ahmed et al., 2020). A RBFNN pode ser expressa pela seguinte equação matemática (Johnsson, 2006):

$$Y = \sum_{K=1}^K W_K \varphi(u; t_K) + W_o \quad (3.11)$$

Onde, o termo $(U; t_K)$ representa a função de base radial que efetua o cálculo da similaridade existente entre u que representa o vetor de entrada e o seu próprio centro t_K . A saída da unidade RBF resulta de uma função não linear que depende da distância entre u e t_K . W_o representa o valor de viés, enquanto W_k , W_1 são os pesos (fatores de escala) atribuídos às saídas de cada unidade RBF. O resultado (valor real) de uma unidade oculta é determinado através da seguinte expressão:

$$\varphi(u; t_K) = \exp\left(-\frac{1}{\sigma_k^2}(u - t_K)^H(u - t_K)\right) \quad (3.12)$$

Onde, σ representa a largura da função gaussiana, o vetor de entrada u e o centro t_K são ambos valores complexos. O expoente H está relacionado à operação hermitiana, que corresponde à transposição conjugada de uma matriz. O cálculo da saída complexa da rede RBF é determinado pela seguinte fórmula:

$$Y = \sum_{K=1}^K W_K \exp\left(-\frac{1}{\sigma_k^2}(u - t_K)^H(u - t_K)\right) + W_o \quad (3.13)$$

A largura σ (um valor real) dos centros para cada unidade oculta pode ser diferente, tanto para valores reais quanto complexos, ou pode ser definida como um valor fixo. No entanto, se for definido um valor fixo, o treino será mais simples.

De acordo com Johnsson, (2006), uma abordagem de treino básica envolve selecionar aleatoriamente um conjunto de exemplos de treino para servirem como os centros de base radial t_K nas unidades da camada oculta. Os pesos são então determinados utilizando o método dos mínimos quadrados. Neste método, parte-se do pressuposto que os dados de treino refletem uma distribuição representativa. Geralmente, a largura da função Gaussiana é estabelecida como um valor fixo, enquanto os pesos da camada de saída são ajustados usando o método dos mínimos quadrados.

Uma limitação desta abordagem é a falta de garantia de um desempenho preciso. Além disso, para atingir um determinado nível de desempenho, esta metodologia muitas vezes leva a uma rede desnecessariamente volumosa, o que pode resultar em problemas de condicionamento numérico. Na Figura 3.10, é apresentado o esquema de uma estrutura RBFNN com uma única saída.

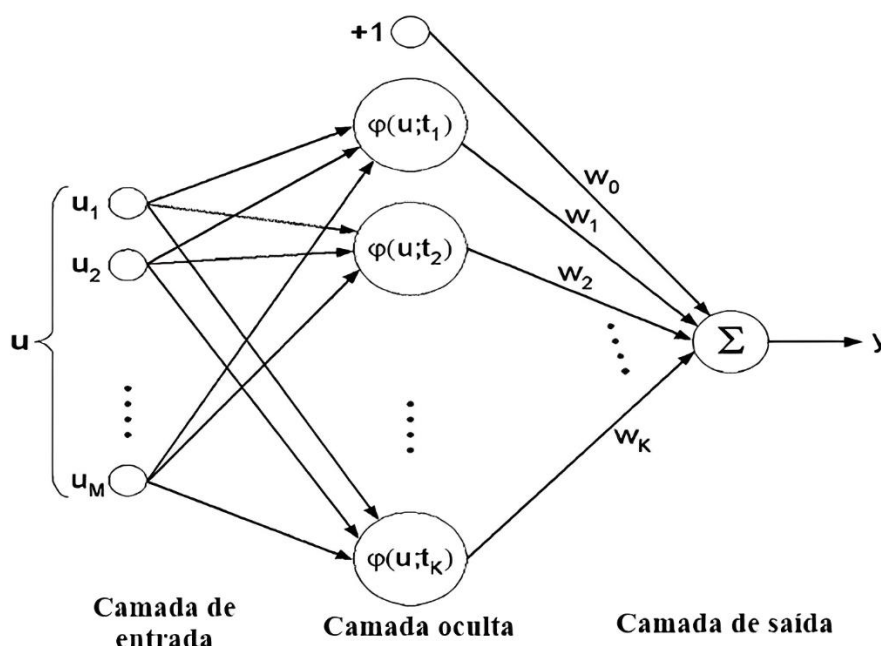


Figura 3.10 – Representação esquemática de uma RBFNN com uma única saída adaptado de (Johnsson, 2006).

Outros métodos baseados em ANN para a previsão da potência de saída de sistemas fotovoltaicos são abordados de forma resumida na Tabela 3.1.

Tabela 3.1 - Resumo de métodos baseados em ANN para previsão da potência FV.

Referência	Tipo de Algoritmo ANN	Designação	Foco Principal
(Rodríguez et al., 2021)	FFNN	Redes neuronais Feedforward	Previsão de energia solar fotovoltaica para um horizonte de muito curto prazo
(Grimaccia et al., 2011)	ANFIS	Sistemas adaptativos de interface neuro-fuzzy	É frequentemente utilizado para previsões não lineares, utilizando amostras passadas para antecipar resultados futuros.
(Maliki et al., 2004)	MLFFNN	Rede neuronal feedforward de múltiplas camadas	Previsão e reconhecimento de padrões são algumas das muitas áreas nas quais essa ANN tem encontrado aplicações

(Ibrić et al., 2012)	GRNN	Rede neuronal de regressão geral	É uma rede composta por quatro camadas, e possui a capacidade de modelar a função diretamente a partir dos dados.
(Bizzarri et al., 2013)	BPNN	Rede neuronal de retropropagação	Excelente função de mapeamento não linear, grande poder de resolução de problemas de regressão complexos.
(Lim et al., 2022)	CNN	Rede neuronal convulucional	Previsão estável de energia solar fotovoltaica
(C. H. Liu et al., 2021)	LSTM	Memória de longo curto prazo	Uma rede neuronal simplificada para previsão da energia FV com um dia de antecedência

3.5.2 Máquinas de Vetor de Suporte

A máquina de vetor de suporte é um método supervisionado de ML que se baseia no princípio da minimização dos riscos estrutural (Rodríguez et al., 2021). Este princípio opera ao reduzir o limite superior do risco esperado. Dessa forma, a técnica SVM visa minimizar os erros nos dados de entrada durante o Treino (Iheanetu, 2022). Essa técnica foram empregadas em diversos domínios importantes, como hidrologia, computação e áreas ambientais. Esta metodologia é frequentemente empregada em áreas como análise de regressão, previsão, classificação e identificação de padrões.

De acordo Sobri et al., (2018), o SVM em comparação a outros métodos, como as ANN e outros modelos estatísticos convencionais, demonstraram resultados superiores. Esses modelos podem evitar o ajuste excessivo dos dados de treino como foi referido anteriormente, eliminar a necessidade de ajuste iterativo dos parâmetros do modelo, utilizar poucos kernels, realizar cálculos mais rápidos e demonstrar boa capacidade de generalização e convergência.

Segundo Olatomiwa et al., (2015), a máquina de vetor de suporte pode ser expressa pela seguinte expressão:

$$F(X) = W\varphi(X) + b \quad (3.14)$$

$$R_{SVM(C)} = \frac{1}{2} \|W\|^2 + C \frac{1}{N} \sum_{i=1}^n L(X_i, d_i) \quad (3.15)$$

Onde, $\varphi(X)$ representa a característica de espaço de alta dimensão que foram mapeadas para o vetor de espaço de entrada (X), W representa o vetor normal, o b é vetor escalar, e

$C \frac{1}{N} \sum_{i=1}^n L(X_i, d_i)$ representa o risco empírico. As variáveis W e b podem ser determinadas ao minimizar a função de custo regularizada, começando com os parâmetros de folga positivos ξ_i e ξ_i^* que indicam os desvios superiores e inferiores. E é dada pela expressão:

$$\text{Minimização} \quad R_{SVM}(w, \xi_i, \xi_i^*) = \frac{1}{2} \|W\|^2 + C \frac{1}{N} \sum_{i=1}^n L(\xi_i, \xi_i^*) \quad (3.16)$$

$$\text{Sujeito a} \quad \begin{cases} d_i - W\varphi(X) + b_i \ll \varepsilon + \xi_i \\ W\varphi(X) + b_i - d_i \ll \varepsilon + \xi_i \\ \xi_i, \xi_i^* \gg 0, \quad i = 1, \dots, l \end{cases} \quad (3.17)$$

Onde, $\frac{1}{2} \|W\|^2$ representam o factor de regulação, C corresponde o coeficiente de penalização do erro utilizado para ajustar a ponderação entre o termo de regularização e o risco empírico. ε é a representação da função de perda que corresponde à precisão da estimativa do ponto de dados de treino. e l representa a quantidade de elementos no conjunto de dados de Treino. Sobri et al., (2018) afirma que, se pode resolver a equação (3.14), ao se introduzir o multiplicador de Lagrange e restrições de otimalidade. A equação passa a ser escrita da seguinte forma:

$$F(X) = \sum_{i=1}^l (\beta_i - \beta_i^*) K(X_i, X_j) + b \quad (3.18)$$

Onde, $K(X_i, X_j) = \varphi(X_i)\varphi(X_j)$. O termo $K(X_i, X_j)$ faz referência a função de kernel, que é o produto interno do vetor X_i e X_j no espaço de característica $\varphi(X_i)$ e $\varphi(X_j)$ respectivamente.

As funções SVM são projetadas para estabelecer a relação entre dados ao realizar um mapeamento não linear. Os métodos de kernel devem ser capazes de operar num espaço de características implícito e de alta dimensão, sem a necessidade de calcular diretamente as coordenadas dos dados nesse espaço, apenas calculando os produtos internos entre as imagens de todos os pares de dados no espaço de características (Murugan et al., 2023). Esse método é conhecido como a abordagem de cálculo direto da função de kernel, simbolizada por K .

As funções kernels podem ser classificados em quatro categorias principais: linear, sigmoide, polinomial e funções de base radial (RBF). Dentre essas, a RBF sobressai como a mais eficaz, principalmente pela sua eficiência computacional e confiabilidade. Além disso, destaca-se pela sua flexibilidade, que permite uma fácil adaptação e otimização em técnicas adaptativas, além de ser capaz de lidar bem com parâmetros complexos (Olatomiwa et al., 2015). Na Figura 3.11, é representado um esquema da estrutura básica de uma SVM. Esta

estrutura compreende camadas de entrada com dimensão p , uma camada oculta com produtos internos do kernel j , e uma camada de saída linear. A função de kernel RBF simplifica o processo de treino, pois necessita apenas da resolução de um conjunto de equações lineares, ao invés de enfrentar um problema longo e complexo de programação quadrática (Olatomiwa et al., 2015). A função não linear de kernel RBF é determinada por:

$$K = (X_i, X_j) = e^{\gamma \|X_i - X_j\|^2} \quad (3.19)$$

Onde, X_i, X_j são vectores de entrada. O parâmetro $\gamma = -1/2\sigma^2$, onde σ do parâmetro γ representa o desvio padrão do ruído gaussiano. Os três parâmetros associados aos kernel RBF são γ , ε e C . A eficácia do modelo SVM está intimamente ligada à seleção adequada destes parâmetros. A forma como estes são definidos pode influenciar significativamente o desempenho do modelo.




Figura 3.11 – Estrutura básica de uma SVM (Sobri et al., 2018).

3.5.3 Máquina de Aprendizagem Extrema

Devido à lentidão na taxa de aprendizagem das redes neuronais Feedforward, causada pelo uso extensivo de algoritmos baseados em gradientes, que são demorados para treinar a rede e ajustar seus parâmetros, Huang et al., (2006) propuseram uma solução para esse problema com o desenvolvimento da ELM. Este novo algoritmo para redes neuronais de alimentação direta com uma única camada oculta (SLFN) demonstrou ser mais rápido em comparação com os algoritmos convencionais de aprendizagem amplamente utilizados. No método ELM, a escolha dos neurónios ocultos é feita de forma totalmente aleatória, influenciando os pesos da camada de saída da SLFN. Uma das grandes vantagens da abordagem ELM é a simplicidade do processo de Treino da rede neuronal (M. Hossain et al., 2017). A Figura 3.12, apresenta a um fluxograma típico de uma ELM.

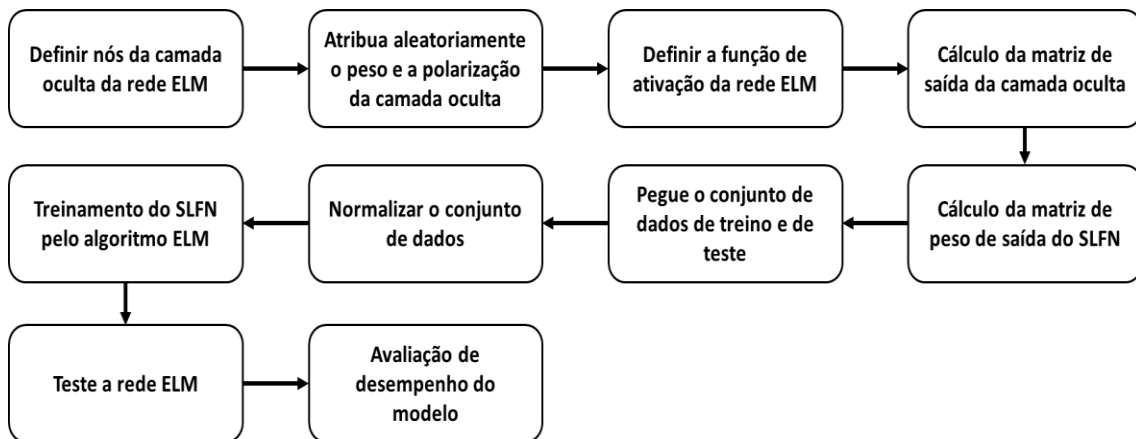


Figura 3.12 – Fluxograma típico de uma máquina de aprendizado extremo (Sobri et al., 2018).

Ao contornar desafios típicos das redes neuronais convencionais, como o sobre ajuste e mínimos locais, o ELM simplifica o procedimento de Treino. Isso resulta em uma redução significativa do custo computacional e em maior capacidade de generalização (Bazionis et al., 2023). A Figura 3.13, ilustra a estrutura básica de uma ELM.




Figura 3.13 – Estrutura básica de uma ELM adaptado de (Sobri et al., 2018).

A estrutura da rede ELM, como outra qualquer ANN, inclui camada de entrada, oculta e camada de saída como é ilustrado pela Figura 3.13 o valor da saída da rede é calculado com base nos dados das amostras usados no Treino, com os enésimos neurónios e através de uma função de ativação $g(W_i, X_i + b_i)$. E é determinada pela seguinte expressão:

$$Y_j = \sum_{i=1}^k \beta_i g(W_i, X_i + b_i) \quad (3.20)$$

Onde, os vectores de peso que conectam os neurónios da camada de entrada e saída aos neurónios da cama oculta i são representados por W_i , β_i , e b_i é o viés dessa rede.

3.6 Previsão Baseada em Métodos Híbridos

É frequente que modelos individuais deixem passar certas informações devido às diferentes maneiras como cada técnica transforma os dados. Por isso, é comum recorrer à combinação de técnicas para aproveitar suas respectivas vantagens e aprimorar a precisão. Como referido anteriormente por Iheanetu, (2022), para superar as limitações técnicas de um único modelo de previsão e aumentar a precisão das previsões, utiliza-se frequentemente modelos híbridos que combinam dois ou mais modelos de previsão. Esses sistemas mitigam as limitações de cada um, resultando em uma precisão de previsão dos sistemas FV muito superior à de métodos individuais. Ao formar o modelo híbrido composto, é crucial escolher cuidadosamente as técnicas individuais, pois o baixo desempenho de qualquer técnica isolada terá impacto no desempenho global do modelo híbrido, o que pode comprometer a precisão das previsões como um todo.

Conforme mais técnicas são integradas ao sistema híbrido, sua complexidade e custo aumentam. No entanto, a busca pela melhoria da precisão das previsões permanece como objetivo principal, exigindo um equilíbrio cuidadoso entre precisão, complexidade computacional e custo. A seleção dos parâmetros de entrada também desempenha um papel crítico nesse processo (Antonanzas et al., 2016).

Dados históricos precisos, que incorporam um maior conjunto de parâmetros como temperatura, pressão e humidade, tendem a proporcionar previsões mais precisas. No entanto, à medida que o número de parâmetros de entrada aumenta, a complexidade também aumenta. Portanto, é crucial selecionar um conjunto ótimo de parâmetros de entrada que apresentem forte correlação com a saída de potência FV, garantindo assim previsões adequadas.

De acordo com Guermoui et al., (2020), os métodos híbridos podem ser classificados em diferentes grupos. Ao classificar os modelos híbridos em grupos distintos, o ponto crucial envolve determinar a natureza da técnica de pré-processamento empregada. A Tabela 3.2 resume os modelos híbridos organizados em seis categorias distintas conforme o método de pré-processamento adotado (B. Yang et al., 2023).

Tabela 3.2 – Classificação dos métodos híbridos com base no modelo de pré-processamento de dados.

Métodos híbridos	Designação
GELA	Abordagem geral de aprendizagem em Conjunto
CELA	Abordagem de aprendizagem em conjunto baseada em <i>clusters</i>
DELA	Abordagem de aprendizagem em conjunto baseada em decomposição
CDELA	Abordagem de aprendizagem em conjunto baseada em decomposição e <i>clustering</i>
EELA	Abordagem de aprendizagem em conjunto baseada em evolução
RELA	Abordagem de aprendizagem em conjunto baseada em resíduo

No presente trabalho, serão destacados quatro dos métodos apresentados, conforme a classificação sumarizada na Tabela 3.2, que organiza os modelos híbridos em seis categorias nos passos que se seguem.

3.6.1 Abordagem Geral de Aprendizagem em Conjunto

A abordagem geral de aprendizagem em Conjunto fundamenta-se na premissa de que cada modelo contribui de forma única para o processo de previsão. Por exemplo, nos estudos referidos no estado da arte, no subcapítulo 2.5, foi apresentado um estudo onde diferentes modelos foram agrupados através de diversos métodos com o objetivo de melhorar o desempenho da previsão final. A Figura 3.14, mostra o modelo de um GELA.

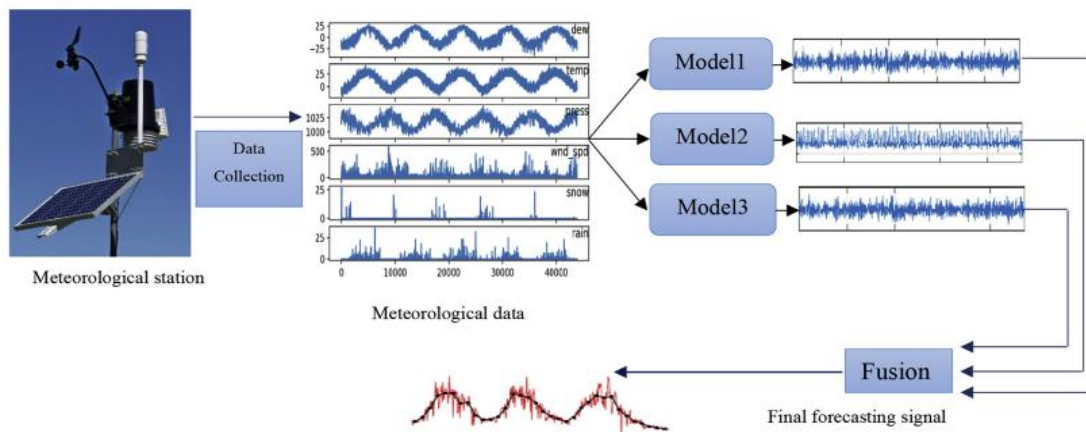


Figura 3.14 – GELA (Guermoui et al., 2020).

3.6.2 Abordagem de Aprendizagem em Conjunto Baseada em Clusters

Diferente da GELA, a abordagem de aprendizagem baseada em conjunto de cluster, Baseiam-se principalmente na aplicação de técnicas de mineração de dados, onde conjuntos de dados são agrupados em clusters distintos, cada um contendo amostras que partilham características similares. Posteriormente, cada cluster é associado a modelos de previsão, sejam eles lineares ou não lineares. Depois, obtém-se o sinal de previsão final agregando os sinais estimados de cada agrupamento. Normalmente, utilizam-se o algoritmo não supervisionado K-means e suas variações para realizar o clustering (Guermoui et al., 2020). A Figura 3.15 mostra a CELA.

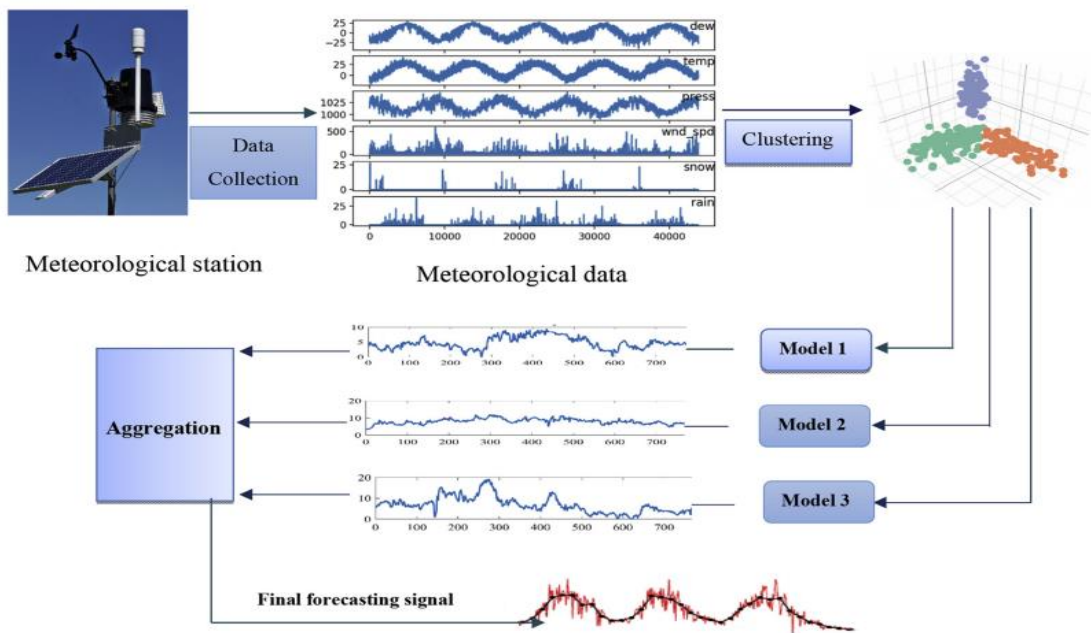


Figura 3.15 – CELA (Guermoui et al., 2020).

3.6.3 Abordagem de Aprendizagem em Conjunto Baseada em Decomposição

Na abordagem de aprendizagem em conjunto baseada em decomposição (DELA) a ideia central reside na decomposição do sinal não estacionário em múltiplos componentes significativos, de forma a tornar estacionários os dados da série temporal. Cada componente é previsto individualmente, e os resultados de previsão são alcançados ao agregar todas as previsões desses componentes em um único sinal como ilustra a Figura 3.16.

No entanto, os componentes de alta frequência são estimados usando modelos não lineares, enquanto os componentes de baixa frequência são determinados por meio de modelos lineares. O resultado da previsão é obtido somando-se os resultados dos modelos lineares e não lineares.

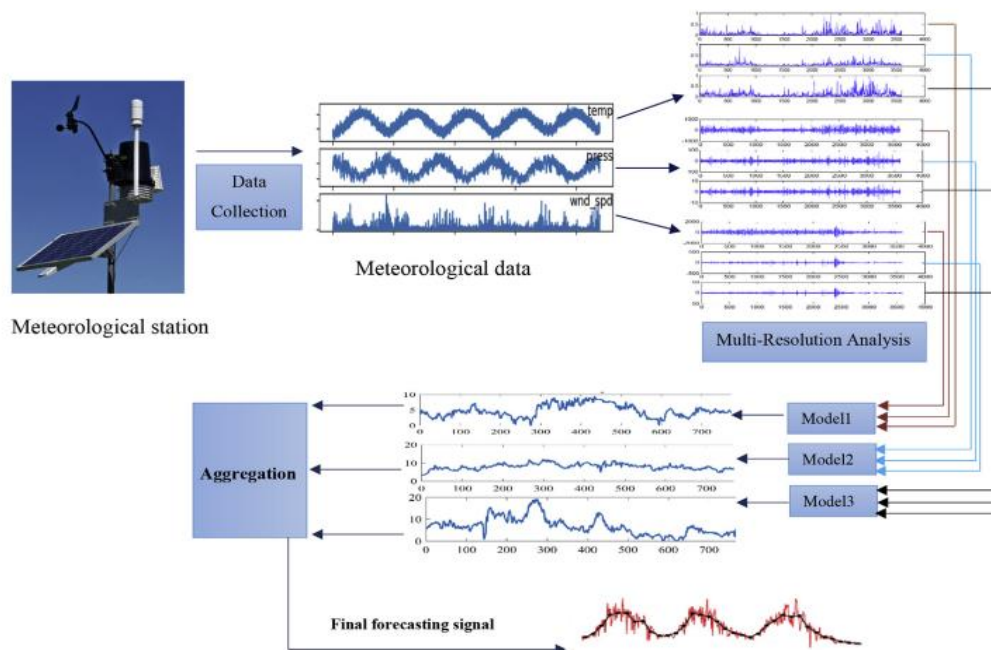


Figura 3.16 – DELA (Guermoui et al., 2020).

3.6.4 Abordagem de Aprendizagem em Conjunto Baseada em Resíduo

Não tão distante da abordagem anterior, a abordagem de aprendizagem em conjunto residual (RELA) se concentra na separação dos componentes lineares e não lineares da radiação solar para previsão de energia FV como se pode observar na Figura 3.17. A premissa subjacente a este método é que a radiação é composta por esses dois componentes distintos. Para os componentes lineares, é empregue um modelo linear simples, enquanto o componente residual é modelado usando um modelo não linear. O resultado é determinado pela soma desses modelos (lineares e não lineares).

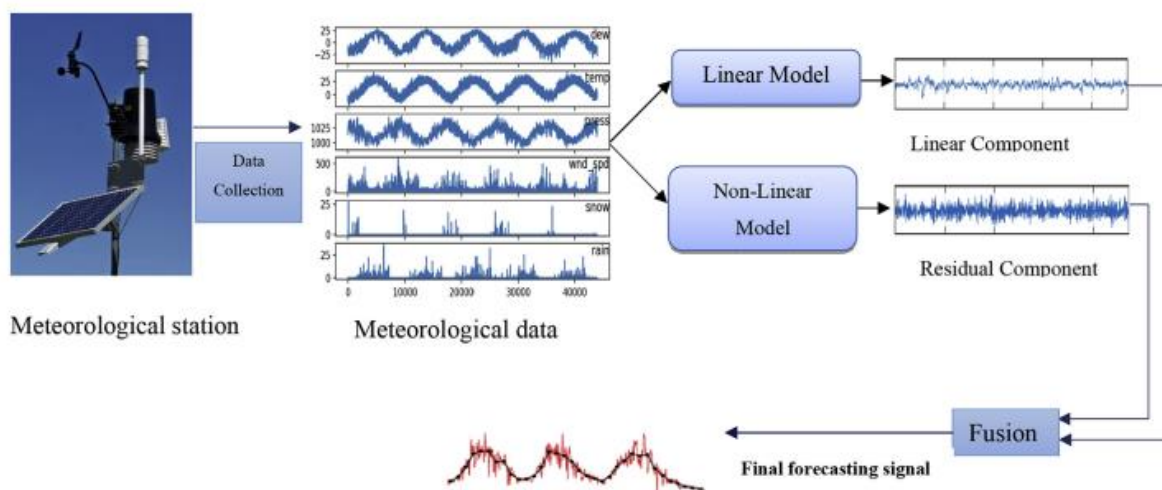


Figura 3.17 – RELA (Guermoui et al., 2020).

A Tabela 3.3 lista diversos métodos combinados empregados na previsão de energia solar fotovoltaica, agrupando-os conforme as abordagens híbridas discutidas previamente. Os métodos são categorizados conforme as suas respectivas abordagens e técnicas associadas.

Tabela 3.3 – Resumo dos métodos híbridos de acordo a classificação das abordagens.

Tipo de abordagem	Referência	Métodos de previsão	Designação do método	Foco principal
GELA	(Lim et al., 2022)	CNN-LSTM	Redes neuronal convolucional e memória de curto longo prazo	Previsão de energia solar fotovoltaica, boa precisão com dados meteorológicos e padrões históricos.
	(Mellit et al., 2005)	MTM-ANN	Matrizes de transição de Markov e redes neurais artificias	MTM-ANN proporciona um alto desempenho em comparação com os modelos individuais AR, AR-MA e Cadeia de Markov.
	(Dong et al., 2014)	ESSS- ANN	Suavização exponencial em espaço de estado combinada com rede neuronal artificial	Previsão de energia FV. O modelo apresenta resultados significativamente superiores aos modelos ARIMA, SES, LES e RW. A eficácia do modelo é influenciada pela qualidade da resolução das ima-

				gens.
CELA	(Ghofrani et al., 2016)	T.S.C K-means-MLP	Clusterização de Séries Temporais com K-means combinada com redes neuronal múltiplas camadas de percepção	Esta abordagem revelou-se eficaz e mais precisa em comparação com outros métodos como K-means*, K-means++, K-técnicas, SOM e FCM.
	(Azimi et al., 2016)	TB-K-means-ANN	K-means baseado em transformação hibridizado com rede neuronal artificial	Complexidade de processamento. Ultrapassa outros métodos de agrupamento como K-means*, K-means++, K-means e SOM no que diz respeito à exatidão e tempo de processamento.
DELA	(Mohammadi et al., 2015)	WT-SVM	Transformada de wallet combinada com máquina de vetor de suporte	Este modelo apresenta maior precisão de previsão de radiação solar quando comparada com o modelo individuais: ARMA, GP e ANN.
	(Yadav & Behera, 2014)	WT (DB4-RNN	Transformada de wallet combinada com redes neuronais recorrentes	Este modelo melhora a capacidade de previsão em comparação com o modelo individual
EELA	(Salcedo-Sanz et al., 2017)	WRF-CRO-SP-ELM	Combinação de um modelo físico e ELM com um algoritmo de otimização CRO	Apresenta um desempenho melhor do que o Agrupamento do Algoritmo Genético com ELM, Algoritmo Genético com ELM+ ELM. Utilizado para previsão da radiação global
	(Mohandes, 2012)	PSO-ANN	Combinação do algoritmo de otimização por enxame e ANN	Estimar a radiação solar fotovoltaica
RELA	(Voyant et al., 2012)	NWP-ARMA-ANN	Previsão numérica de tempo, média móvel autorregressiva e redes neuronal artificial	Previsão de séries temporais de radiação global, utilização de intervalos de confiança para estimar a

				confiabilidade da previsão.
	(Gairaa et al., 2016)	ARMA-ANN	Combinação do modelo autorregressivo de média móvel e ANN	Estimar a radiação global, a principal vantagem reside na capacidade de capturar os pontos fortes de ambos os modelos

A combinação de técnicas para previsão em sistemas fotovoltaicos mostra-se essencial para mitigar as limitações individuais dos modelos. Modelos híbridos, que unem diferentes abordagens como GELA, CELA, DELA, EELA, e RELA, têm demonstrado significativamente maior precisão comparados aos métodos isolados. Esta eficácia é obtida ao integrar as vantagens únicas de cada técnica, resultando em previsões mais confiáveis e adaptáveis às variadas condições ambientais e de dados. No entanto, a escolha cuidadosa dos métodos e parâmetros é crucial para balancear precisão, complexidade computacional e custo, buscando sempre otimizar o desempenho global do modelo híbrido.

3.7 Parâmetros de Entrada dos Modelos de Previsão Fotovoltaicos

A energia solar é uma fonte renovável de extrema relevância, derivada da radiação solar que atinge a Terra. A conversão dessa radiação em eletricidade ocorre através das células fotovoltaicas, utilizando o efeito fotovoltaico. A quantidade de eletricidade produzida pela energia solar depende principalmente da radiação solar, além de fatores como temperatura, vento, humidade. Perdas de energia devido à sujeira acumulada e degradação dos componentes eletrônicos também são levadas a cabo como foi referido anteriormente. Os modelos para previsão da produção de energia fotovoltaica são construídos utilizando dados históricos de séries temporais da potência gerada pelos sistemas FV e das variáveis meteorológicas correspondentes.

Os parâmetros climáticos sofrem variações conforme a região e o clima, que influenciam de forma única a produção de energia fotovoltaica em diferentes locais. A precisão de um modelo de previsão é determinada pela relação entre os parâmetros de entrada (como temperatura, radiação solar, vento, humidade) e a potência produzida. As variáveis altamente correlacionadas são fundamentais como entradas no modelo, enquanto as fracamente correlacionadas podem ser descartadas.

Segundo HUANG et al., (2010), existe uma forte correlação entre a radiação solar e a potência de saída, sendo crucial como vetor de entrada em modelos de previsão de energia

FV. Antes de se projetar um modelo é necessário que se leve em conta a relação entre as variáveis meteorológicas e a potência de saída gerada pelo sistema FV, visto que, a precisão do modelo aumenta à medida que mais variáveis são utilizadas como entradas, mas isso também eleva a complexidade e o custo computacional. Determinar o número ótimo de entradas, com base na correlação e na relevância para a precisão, é fundamental para garantir um equilíbrio entre alta precisão e custo computacional otimizado.

Os dados históricos usados na previsão da produção de energia FV podem conter flutuações ou elementos não estacionários devido às condições meteorológicas variáveis. Elementos identificados como valores atípicos e falhas nos dados de entrada devido a erros de medição também podem introduzir imprecisões na previsão do modelo. Por isso, é crucial realizar o pré-processamento dos dados de entrada para mitigar essas questões. Este processo não só reduz problemas de treino inadequado e custos computacionais, mas também aprimora a exatidão dos modelos de previsão.

No contexto de modelos de previsão, diversas técnicas de pré-processamento têm sido aplicadas para preparar os dados de entrada. Este trabalho apresentará de forma resumida essas técnicas, conforme descrito na Tabela 3.4 (Wu et al., 2022).

Tabela 3.4 – Resumo dos métodos de pré-processamento de dados de entrada.

Técnica de Pré-Processamento	Vantagens	Desvantagens	Aplicações
Limpeza de Dados (Data Cleaning)	Remove outliers e dados desnecessários, melhora a qualidade dos dados	Pode resultar em perda de informações úteis se não feita com cuidado	Preparação de dados para modelos de previsão, eliminação de dados ausentes
Normalização	Escala os dados para o intervalo [0, 1], facilita a convergência e reduz o tempo de Treino	Não altera a distribuição dos dados	Redução da influência de unidades diferentes de dados no modelo, melhoria da eficiência do Treino
Padronização Z-Score	Transforma os dados em uma distribuição normal com média zero e desvio padrão um	Requer que os dados sejam aproximadamente distribuídos normalmente	Melhoria da precisão da previsão em dados normalmente distribuídos, redução de efeitos de <i>outliers</i>
Transformada Wavelet (WT)	Pode identificar frequências existentes nos dados, eficaz contra outliers	Alta complexidade computacional	Análise de séries temporais, previsão de séries temporais, redução de ruído em dados de séries temporais
Decomposição em Modos Empíricos (EMD)	Decomposição direta de sinais não lineares e não estacionários, auto-adaptativo	Problemas com modos misturados nos componentes IMFs	Análise de séries temporais não lineares e não estacionárias, previsão de séries temporais
Análise Espectral Singular (SSA)	Lida com séries temporais não lineares, identifica tendências e sinais periódicos	Requer um bom entendimento teórico e matemático	Análise de séries temporais complexas, previsão de séries temporais, aplicação

	cos	em climatologia e finanças
--	-----	----------------------------

Essa tabela resume as principais técnicas de pré-processamento mencionadas no texto, suas vantagens e desvantagens, bem como suas aplicações típicas na preparação de dados para previsão de potência FV e outras aplicações de séries temporais. Serão destacadas as técnicas mais comumente utilizadas nas bibliografias consultadas.

3.7.1 Normalização

A normalização é uma prática habitual na preparação dos dados de entrada, essencial para desenvolver modelos de previsão da produção de energia dos sistemas fotovoltaicos. Esta técnica visa tipicamente reduzir a amplitude dos valores dos dados de entrada, minimizando erros de regressão e aprimorando a exatidão das previsões. Uma abordagem comum é restringir os dados para um intervalo entre 0 e 1 (Iheanetu, 2022b; Wu et al., 2022). A normalização é dada pela expressão matemática:

$$P_{normalizado} = \frac{P_{actual} - P_{min}}{P_{Max} - P_{min}} \quad (3.21)$$

Onde, os dados normalizados são representados por $P_{normalizado}$, P_{actual} são os dados medidos e o P_{Max} e P_{min} são os valores máximos e mínimos medidos respectivamente.

3.7.2 Transformada de Wavelet

A Transformada Wavelet (WT) demonstra ser eficaz na análise de séries temporais convencionais por meio de abordagens que exploram tanto o domínio temporal quanto o domínio da frequência. Nos métodos que se centram no domínio temporal, uma série temporal é interpretada como uma sequência de pontos ordenados, com análise subsequente da correlação entre esses pontos. Por outro lado, nos métodos que exploram o domínio da frequência, a série temporal é transformada em um espectro, sendo este último então analisado como características principais (Alipour et al., 2020).

Conforme citado por Alipour et al., (2020), a técnica WT permite a análise de dados considerando tanto o comportamento temporal quanto a frequência, usando uma wavelet mãe como referência. Este método identifica as frequências existentes nos dados e os momentos em que ocorrem. Além disso, os extremos nos dados têm um efeito minimizado nas previsões obtidas. No entanto, após a escolha da função base, não é viável ajustar completamente o processo de cálculo, revelando uma restrição em termos de flexibilidade.

Esta abordagem revela-se particularmente eficaz na avaliação de séries temporais, destacando a relevância de certas frequências para o processo de modelação e previsão, apesar da restrição em termos de ajustes após a escolha da função fundamental.

3.8 Métricas de Desempenho Para Avaliação da Precisão de Previsão

A exatidão das previsões solares é fortemente influenciada por dois fatores essenciais: a localização geográfica e o horizonte temporal da previsão (Sobri et al., 2018). A avaliação do desempenho e da precisão de um modelo específico pode ser realizada por meio de diversas métricas. De acordo com Antonanzas et al., (2016) , as métricas possibilitam a comparação entre modelos e locais distintos, concentrando-se em diferentes aspectos de uma distribuição de pontos. Assim, não existe uma métrica universal que se aplique a todas as situações; ao contrário, cada métrica oferece informações adicionais sobre a precisão do modelo.

Segundo a pesquisa realizada em diversas fontes bibliográficas, identificou-se que várias métricas têm sido estudadas ao longo do tempo, embora um conjunto específico delas seja mais frequentemente utilizado. Nos próximos passos são apresentadas as métricas comumente utilizadas:

3.8.1 Erro Médio Absoluto e Erro Médio Quadrático

O erro médio absoluto (MAE) é uma métrica que indica a média das diferenças absolutas entre as previsões do modelo e os valores reais. Esta métrica é calculada utilizando a fórmula seguinte (Notton et al., 2013):

$$MAE = \frac{1}{N} \sum_{i=1}^N |W_{prev} - W_{med}| \quad (3.22)$$

Onde, W_{prev} representa a potência prevista e, W_{med} é a potência real medida. O MAE pode variar o seu valor de 0 ao infinito.

Em comparação com o MAE o erro quadrático médio (MSE) é calculado elevando ao quadrado todas as diferenças entre as previsões e os valores reais, somando esses quadrados para obter um valor médio que avalia a dispersão dos valores. Esta métrica é determinada através da seguinte expressão (Patel et al., 2021):

$$MSE = \frac{1}{N} \sum_{i=1}^N (W_{prev} - W_{med})^2 \quad (3.23)$$

Onde, W_{prev} representa a potência prevista e, W_{med} é a potência real medida.

3.8.2 Raiz do Erro Médio Quadrático

A raiz do erro médio quadrático (RMSE) que é também chamado de desvio padrão, pode ser um indicador preciso da qualidade da previsão quando o erro não é óbvio (R. Ahmed et al., 2020). A média do erro é calculada utilizando a raiz quadrada da média dos quadrados das diferenças entre os valores previstos e as observações reais. Esta característica torna-o mais robusto ao lidar com grandes desvios, que são particularmente indesejáveis, facilitando a identificação e eliminação de valores anômalos. Esta métrica é calculada pela seguinte expressão (Fernandez-Jimenez et al., 2012):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (W_{prev} - W_{med})^2} \quad (3.24)$$

Onde, W_{prev} representa a potência prevista e, W_{med} é a potência real medida

3.8.3 Erro Médio Percentual Absoluto

O erro médio percentual absoluto (MAPE) calcula a média dos erros percentuais absolutos entre os valores previstos e os valores reais, expressando-os como uma percentagem. É a métrica que quantifica a média da distância entre as previsões do modelo e suas respectivas saídas. E é dada pela seguinte expressão (Patel et al., 2021):

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|W_{prev} - W_{med}|}{W_{med}} \times 100\% \quad (3.25)$$

Uma das principais vantagens do MAPE é que ele expressa o erro como uma percentagem, o que facilita a interpretação dos resultados. No entanto, o MAPE pode apresentar problemas quando os valores reais são próximos de zero, pois isso pode levar a erros percentuais extremamente altos ou indefinidos.

3.8.4 Erro Médio Relativo

O erro médio relativo (MRE) mede a média dos erros relativos entre os valores previstos e os valores reais. Ele expressa a precisão da previsão em termos de uma percentagem média de desvio em relação aos valores reais. E é expressa pela expressão (Nespoli et al., 2018) :

$$MRE = \frac{1}{N} \sum_{i=1}^N \frac{(W_{prev} - W_{med})}{W_t} \times 100\% \quad (3.26)$$

Onde, W_{prev} , W_{med} , W_t representam as respectivas potências previstas e medidas.

3.8.5 Erro Médio de Biés

O erro médio de biés (MBE) calcula a média das diferenças entre os valores previstos e os valores reais, sem considerar a direção dos erros. Isso mostra se as previsões geralmente estão acima ou abaixo dos valores reais de maneira consistente. e é expressa pela seguinte formula (Mathiesen & Kleissl, 2011) :

$$MBE = \frac{1}{N} \sum_{i=1}^N (W_{prev} - W_{med}) \quad (3.27)$$

De acordo com A. Ahmed & Khalid, (2019), Alguns investigadores argumentaram que as métricas de erro são insuficientes para a avaliação dos modelos. Propuseram, em alternativa, avaliações mais focadas na aplicação prática, como calcular a precisão ideal considerando a economia do sistema e o planeamento estratégico. Isso inclui áreas como gestão económica, armazenamento de energia, políticas de mercado emergentes e maximização dos lucros.

Independentemente da métrica utilizada para avaliação, é crucial realizar uma análise imparcial de um modelo de previsão específico. Isso possibilita que especialistas tomem decisões bem fundamentadas quanto ao projeto, instalação e utilização de sistemas de energia solar fotovoltaica para integração na rede elétrica

3.9 Análise Comparativa dos Métodos de Previsão de Produção de Energia Solar Fotovoltaica

Com base na análise dos diversos métodos de previsão discutidos neste trabalho, é evidente que cada abordagem possui suas vantagens e desvantagens. Ao comparar os métodos de previsão, é crucial considerar diversos parâmetros que têm um impacto significativo no desempenho do modelo. Estes parâmetros incluem o horizonte temporal desejado para a previsão, os tipos e a qualidade dos dados de entrada disponíveis, o contexto específico de aplicação e a complexidade computacional dos modelos.

Os modelos NWP, por exemplo, oferecem previsões de longo prazo com ampla cobertura geográfica, mas podem ser computacionalmente intensivos. Já métodos como o SI e a captura de imagens por satélite oferecem previsões de curto e médio prazo, respectivamente, mas enfrentam limitações relacionadas à área de cobertura e à precisão em condições climáticas variáveis. Métodos estatísticos e de aprendizado de máquina, como a EWMA, ARIMA, ANN, e SVM, oferecem abordagens sofisticadas para análise de séries temporais e previsão, cada um com sua própria capacidade de lidar com dados históricos e atuais. Por fim, as com-

binacões destas técnicas em modelos híbridos podem mitigar as limitacões de métodos individuais, que resultam em uma maior precisão nas previsões de energia FV, embora também aumentem a complexidade e o custo computacional.

Assim, na Tabela 3.5, são resumidos os principais métodos abordados neste trabalho para a previsão da producao de energia solar fotovoltaica, destacando as suas aplicacões, bem como as suas vantagens e desvantagens.

Tabela 3.5 – Análise comparativa dos diversos métodos de previsão de producao FV

Métodos de Previsão FV	Aplicação	Parâmetros de Entrada	Vantagens	Desvantagens
Físico	Utiliza dados meteorológicos em físicas para prever a producao de energia	Irradiância solar, precipitacão, temperatura, humidade, pressão atmosférica, velocidade do vento, topografia	Precisão em condições climáticas estáveis. Modelos detalhados. Utiliza dados extensivos	Complexidade elevada. Sensível a mudanças climáticas. Requer dados meteorológicos detalhados
Estatístico	Previsão baseada em dados históricos	Dados históricos de producao de energia e condições climáticas	Independente de parâmetros físicos. Adaptável a diferentes condições. Utiliza IA para aumento da precisão	Dependência da qualidade e comprimento dos dados histórico. Possibilidade de erros de aprendizado. Requer um histórico de dados preciso.
Híbrido	Combinação de técnicas físicas e estatísticas para maior precisão	Combinação de dados meteorológicos e históricos	Maior precisão. Versátil em várias condições. Aproveita dados avançados e técnicas de medição.	Aumento da complexidade. Necessita de dados de alta qualidade. Depende da qualidade dos modelos físico e estatístico

Em resumo, cada método de previsão de energia solar possui suas particularidades, os métodos físicos oferecem alta precisão em condições estáveis, mas são complexos e dependentes de dados meteorológicos; os métodos estatísticos são mais simples e adaptáveis, porém dependem da qualidade dos dados históricos; os métodos híbridos combinam as vantagens dos anteriores, aumentando a precisão, mas também a complexidade e a necessidade de dados de alta qualidade. A escolha do método deve considerar as condições específicas e a disponibilidade de dados.

CASOS DE APLICAÇÃO: PREVISÃO DE PRODUÇÃO DE ENERGIA SOLAR FOTOVOLTAICA

Neste capítulo, é apresentado um caso prático em que é implementado um modelo de previsão de energia solar fotovoltaica a curto prazo, que utiliza dados históricos de produção (dados meteorológicos e dados de potência) provenientes de uma instalação fotovoltaica situada na Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa no Monte da Caparica, Almada, Setúbal. A Figura 4.1, apresenta um fluxograma que ilustra a metodologia utilizada para a previsão de potência a curto prazo na instalação de referência.

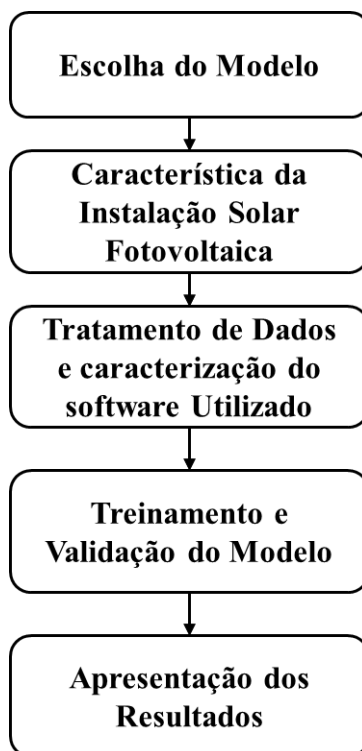


Figura 4.1- Fluxograma do processo de aplicação do modelo escolhido para a previsão.

4.1 Escolha do Modelo

Como mencionado nos capítulos anteriores, a escolha do modelo de previsão para a produção de energia solar fotovoltaica depende de vários fatores que afetam o desempenho do modelo, como o horizonte temporal da previsão, o local de aplicação, os recursos computacionais disponíveis, a disponibilidade dos dados de entrada necessários, a necessidade de prever a energia gerada para uma gestão eficaz da central, além da precisão comparativa do modelo em relação a outros métodos.

Com base na literatura revisadas, diversos estudos exploraram uma variedade de métodos para prever a produção de energia FV, com especial ênfase na otimização das previsões de curto prazo. Esses estudos destacam tanto as vantagens quanto as desvantagens de cada abordagem. Entre as técnicas examinadas, as ANN emergem como uma das mais eficazes para a previsão de curto prazo da produção de energia FV. No âmbito deste estudo, é apresentado um método de previsão baseado em ANN, voltado para previsões de curto prazo da energia solar fotovoltaica. A escolha desse método é fundamentada pelas seguintes razões:

- **Capacidade de modelar as não linearidades:** A capacidade das ANN em lidar com não linearidades é notável, especialmente na sua habilidade de capturar relações complexas entre variáveis. Isso é crucial para prever fenômenos meteorológicos complexos, que métodos lineares não conseguem prever adequadamente.
- **Adaptabilidade e autoadaptação:** Durante o Treino, este método ajusta seus pesos automaticamente para otimizar a precisão da previsão com base nos dados disponíveis. Isso permite que o modelo se adapte a mudanças nas condições meteorológicas ao longo do tempo sem necessidade de ajustes manuais constantes.
- **Tolerância a falhas:** As ANN são resilientes ao lidar com dados meteorológicos que frequentemente são incompletos, ruidosos ou contêm outliers. Elas conseguem oferecer previsões estáveis e confiáveis mesmo diante de condições adversas.
- **Horizonte temporal:** O método escolhido apresenta maior eficácia em previsões de curto prazo e médio prazo, dependendo da quantidade e qualidade dos dados históricos disponíveis para Treino.
- **Facilidade de implementação e manutenção:** Após o Treino, as redes neurais artificiais podem ser mais facilmente atualizadas e ajustadas à medida que novos dados se tornam disponíveis.

Comparativamente aos modelos descritos, as ANN podem ser uma opção viável onde há altos custos operacionais dos modelos NWP. Além disso, são menos influenciadas pelas condições iniciais, o que pode ser uma vantagem significativa em previsões. Em comparação com modelos ARIMA, ARMA e outras abordagens estatísticas, as ANN são mais adequadas

para capturar padrões não lineares e complexos que podem existir nos dados meteorológicos, especialmente em casos onde há autocorrelação complexa ou mudanças abruptas.

Embora os SVM também sejam eficazes na modelagem de não linearidades, as ANN geralmente oferecem maior flexibilidade na arquitetura da rede e na adaptação dinâmica durante o Treino, o que pode resultar em melhores previsões em cenários meteorológicos variados.

4.2 Caracterização da Instalação Solar Fotovoltaica

A instalação solar fotovoltaica em estudo está localizada na Faculdade de Ciência e Tecnologia da Universidade Nova de Lisboa (FCT/UNL), situada no Monte de Caparica, Almada, Setúbal.




Figura 4.2 – Imagem da (FCT/UNL) Obtida via google mapa.

A instalação usada para a recolha dos dados é composta por um conjunto de sete módulos fotovoltaicos, sendo que cinco são de silício amorfo (modelo BS40 da Bangkok Solar) e os dois restantes de silício policristalino (modelo SWL 130 da SWEA). Estes módulos estão instalados no topo do Departamento de Engenharia de Eletrotécnica e de Computadores (DEEC), como mostra a Figura 4.3 (Rogado, 2019).



Figura 4.3 – Conjunto de módulos utilizados para colheita de dados (Rogado, 2019)

Os módulos estão organizados em três subconjuntos, que, em conjunto, atingem uma potência nominal total de 460 watts. A instalação inclui ainda três inversores do modelo UWTI-250 da SWEA, com cada inversor ligado a um subconjunto específico de módulos FV (Rogado, 2019).

As características dos dois tipos de painéis FV mencionados anteriormente, em condições STC (irradiância de 1000 W/m² e temperatura da célula a 25°C). são apresentadas na **Tabela 4.1**.

Tabela 4.1 – características técnicas dos diferentes tipo de módulos solares, (Rogado, 2019).

Especificação	Bankok Solar – BS 40	SWEA – SWL 130
Tensão Máxima	44,8 V	44,8 V
Corrente Máxima	0,93 A	3,2 A
Potência máxima	40 W	130 A
Tensão de circuito aberto	62,2 V	50,1 V
Corrente de curto-circuito	1,14 A	3,21 A

4.3 Tratamento de Dados e Caracterização do Software

A base de dados dos preditores (Irradiância e Temperatura) e os dados de potência, utilizados para prever a produção de energia solar fotovoltaica neste trabalho, foram coletados em intervalos de um minuto ao longo do ano de 2013. No entanto, devido a certas limitações técnicas na instalação, foi necessário ajustar esses dados em relação aos valores de potência produzida. Esse processo resultou numa redução significativa na base de dados original. Embora inicialmente se esperassem 8760 amostras que correspondem ao valor total de amostra anual, após a eliminação dos dias em que havia discrepâncias entre os registros de irradiância e a produção de potência, a base de dados final foi reduzida para 5421 amostras que foram utilizadas para as simulações de previsão como ilustram as Figura 4.4 e Figura 4.5.

Para adequar os dados ao tipo de previsão que seria realizada, foram calculadas as médias horárias. Em seguida, os dados foram divididos em dois conjuntos distintos: o primeiro,

composto por 4.606 amostras, foi utilizado para o treino e validação do modelo; o segundo, com 814 amostras, foi reservado para testes. Os dados destinados ao Treino e validação abrangem o intervalo de 1 de janeiro de 2013 até 1 de novembro, conforme as razões mencionadas anteriormente. Já os dados de teste cobrem o período de 2 de novembro até 31 de dezembro.




Figura 4.4 – Gráficos de médias horaria das amostras de irradiância e temperatura utilizada para previsão.

Nas tabelas a seguir, encontram-se alguns pormenores estatísticos relevantes sobre a base de dados.

Tabela 4.2 – Dados estatísticos das amostras de irradiância

Número de amostras	Média (W/m^2)	Desvio Padrão (W/m^2)	Irradiância Máxima (W/m^2)	Irradiância Mínima (W/m^2)
5421	211,1524	294,3141	1040,344	0

Tabela 4.3 – Dados estatísticos das amostras de temperatura.

Número de amostras	Média ($^{\circ}C$)	Desvio Padrão ($^{\circ}C$)	Temperatura Máxima ($^{\circ}C$)	Temperatura Mínima ($^{\circ}C$)
5421	16,2361	5,4932	32,2422	4,6615

Os dados de potência foram tratados com a mesma abordagem que foi aplicada aos dados meteorológicos. O gráfico apresentado na Figura 4.5, ilustra as amostras de potência que foram empregues na previsão.




Figura 4.5 – Gráfico de média horária das amostras de potência utilizada para previsão.

Certas informações relativas à bases de dados de potência estão disponíveis na Tabela 4.4, que apresenta os dados estatísticos correspondentes.

Tabela 4.4 – dados estatísticos das amostras referente a potência medida.

Número de amostras	Média (W)	Desvio Padrão (W)	Potência Máxima (W)	Potência Mínima (W)
5421	69,5084	101,0339	334,106	0,026667

4.3.1 Software Utilizado

Neste trabalho, utilizou-se um *software* de simulação para modelar a produção de energia solar fotovoltaica, optando-se por implementar uma Rede Neuronal Artificial do tipo Feedforward. Esta escolha justifica-se pela estrutura relativamente simples desta ANN e pela sua eficácia no tratamento de dados sequenciais, como os que se referem à produção de energia solar. A configuração da rede neuronal incluiu uma camada de entrada, três camadas ocultas e uma camada de saída, como ilustra na Figura 4.6. Nas camadas ocultas, foi adotada a função de ativação tangente sigmoide, que ajuda a suavizar as transições entre neurónios e a lidar com as não-linearidades presentes nos dados. Para o Treino da rede, selecionou-se o algoritmo *Levenberg-Marquardt*, que é conhecido pela sua eficácia em redes de pequeno a médio porte.

O *software* de simulação oferece uma caixa de ferramentas avançada para redes neuronais, que permite a configuração, o treino e a avaliação de diferentes arquiteturas de ANN. Isso inclui a definição de camadas ocultas, o ajuste de parâmetros, a divisão dos dados em

conjuntos de treino e validação, e a análise do desempenho do modelo através de métricas como MAE, RMSE e MAPE.

Além disso, o *software* utilizado permite a visualização gráfica dos resultados, que ajuda na interpretação dos modelos e a comparação entre previsões e valores reais.




Figura 4.6 – Configuração da Rede Neuronal Artificial usada para previsão

Foram treinadas nove diferentes configurações de Rede Neuronal Artificial, variando apenas o número de neurónios das camadas ocultas. As configurações incluíram redes com uma única camada oculta contendo 5, 10 e 15 neurónios, redes com duas camadas ocultas com combinações de [5, 5]; [10, 10] e [15, 15] neurónios, e, por fim, redes com três camadas ocultas, cada uma com [5, 5, 5]; [10, 10, 10]; e [15, 15, 15] neurónios. A Figura 4.6, ilustra um exemplo de uma ANN com três camadas ocultas, cada uma contendo cinco neurónios.

4.4 Treino e Validação do Modelo

Como mencionado anteriormente, foram treinadas e validadas nove configurações diferentes de ANN para a previsão da produção de energia FV para um horizonte de uma hora. Destas, apenas a configuração que demonstrou o melhor desempenho foi selecionada para os testes de previsão.

Durante a fase de treino e validação, o conjunto de dados reservado para esse propósito foi dividido de acordo com a divisão automática do *software* utilizado a fim de evitar *overfitting*, ou seja, Treino exaustivo da ANN. Um total de 4606 amostras de dados de irradiância, temperatura e potência foram repartidos, com 85% destinados ao treino e 15% à validação. Isso corresponde a 3915,1 amostras utilizadas na fase de treino e 690,9 amostras na validação do modelo. Os dados de treino abrangem o período de 1 de janeiro a 6 de setembro do ano em análise, enquanto os dados de validação cobrem o intervalo de 7 de setembro a 1 de novembro.

Após a separação dos dados pelo *software* utilizado, foram organizados os conjuntos para o treino e validação do modelo. Para isso, os dados de irradiância e temperatura foram utilizados como variáveis de entrada, enquanto os dados de potência foram definidos como variáveis de saída do modelo, conforme ilustra a Figura 4.6. De acordo com as fontes bibliográficas consultadas, é essencial que a rede seja treinada repetidamente para que possa aprender os padrões dos dados e minimizar os erros na fase de previsão. As redes em questão foram treinadas 20 vezes, e a Figura 4.7 apresenta os resultados dos gráficos de regressão nessas fases.

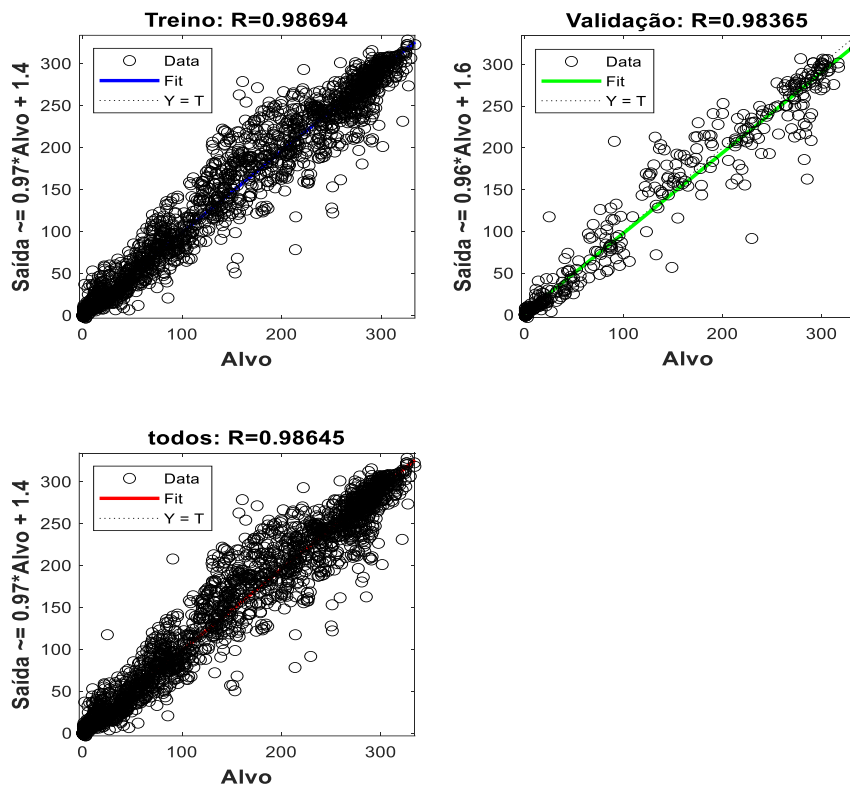


Figura 4.7 – Gráficos de regressão na fase de Treino e validação.

O gráfico de regressão apresentado na Figura 4.7 compara os valores reais (*Alvo*) com os valores previstos pelo modelo (*Saída*). Este gráfico é dividido em três secções. Nos dois primeiros gráficos, são exibidos os resultados do modelo para os dados de Treino e validação, que apresentam um coeficiente de correlação (R) de 0,98694 para o Treino e 0,98365 para a validação, o que indica uma forte correlação entre os valores previstos e os reais, sugerindo assim um bom ajuste do modelo. A linha azul e a linha verde representam as linhas de melhor ajuste para os dados de Treino e validação, enquanto as linhas pretas tracejadas indicam uma previsão ideal.

O gráfico inferior combina os resultados dos gráficos anteriores com um coeficiente de correlação de 0,98645, muito próximo dos anteriores sugerindo que o modelo é consistentemente preciso tanto na fase de Treino quanto na fase de validação.

A análise deste gráfico revela que, quando os pontos pretos estão bem alinhados ao longo da linha de ajuste, isso indica uma forte correlação entre os valores reais e previstos. Quanto mais próximo os pontos estarem dessa linha, mais forte é a relação entre os dados de entrada e saída. A inclinação da linha de melhor ajuste, descrita pela equação da reta (que pode ser observada na Figura 4.7 no eixo das ordenadas) reflete a relação linear entre as variáveis. Se a

linha de melhor ajuste estiver próxima de linha tracejada isso indica que a previsão é quase perfeita como referido anteriormente.

O coeficiente de correlação próximo de 1, como 0.986, sugere uma forte correlação positiva, significando que à medida que o valor de entrada aumenta, o valor predito pelo modelo também aumenta de maneira proporcional. Um valor de R alto indica que o modelo captura bem a relação entre os valores de entrada e saída.

Durante a fase de Treino e validação do modelo foram estimados também o desempenho das nove configurações treinadas e validadas, utilizando as métricas de desempenho descritas no Subcapítulo Métricas de Desempenho Para Avaliação da Precisão de Previsão, a fim de escolher o modelo que apresenta menor erro para posterior aplicação para previsão da potencia produzida num horizonte de uma hora. Como mencionado no subtítulo 3.8.3, a métrica que mais efetivamente avalia a qualidade das previsões é o MAPE, pois, por este ser adimensional e expresso em percentagem, permite uma comparação clara. Quanto mais baixo for o valor do MAPE, mais precisa é a previsão. A tabelas abaixo apresenta os valores dos erros de previsão obtidos durante as fases de treino para as diferentes configurações testadas. Além disso, incluem os gráficos de regressão referentes à configuração que apresentou o melhor desempenho, bem como os resultados do teste de previsão nessas fases.

Tabela 4.5 – Erros de previsão na fase de Treino para as nove configurações.

Configuração da Camada Oculta	Função de Ativação	Neurónios por Camada oculta	MAE (W)	RSME (W)	MAPE (%)
1	Tanh-Sig	5	8,82	17,43	51,60
1	Tanh-Sig	10	8,43	17,12	41,62
1	Tanh-Sig	15	8,42	17,11	45,09
2	Tanh-Sig	5	8,47	17,13	41,53
2	Tanh-Sig	10	8,26	16,90	40,02
2	Tanh-Sig	15	8,12	16,48	45,48
3	Tanh-Sig	5	8,50	17,11	46,26
3	Tanh-Sig	10	8,16	16,52	42,26
3	Tanh-Sig	15	8,20	16,44	51,35

Na Tabela 4.5, são apresentados os resultados das métricas de desempenho durante a fase de Treino do modelo para previsão de energia fotovoltaica, considerando as diferentes

configurações da rede neural artificial para um horizonte de uma hora. A análise das métricas revela que o valor do MAPE varia entre 40% a quase 52%, sendo que a configuração de duas camadas ocultas com 10 neurónio apresentou o menor erro durante o Treino, como ilustra a Figura 4.8.

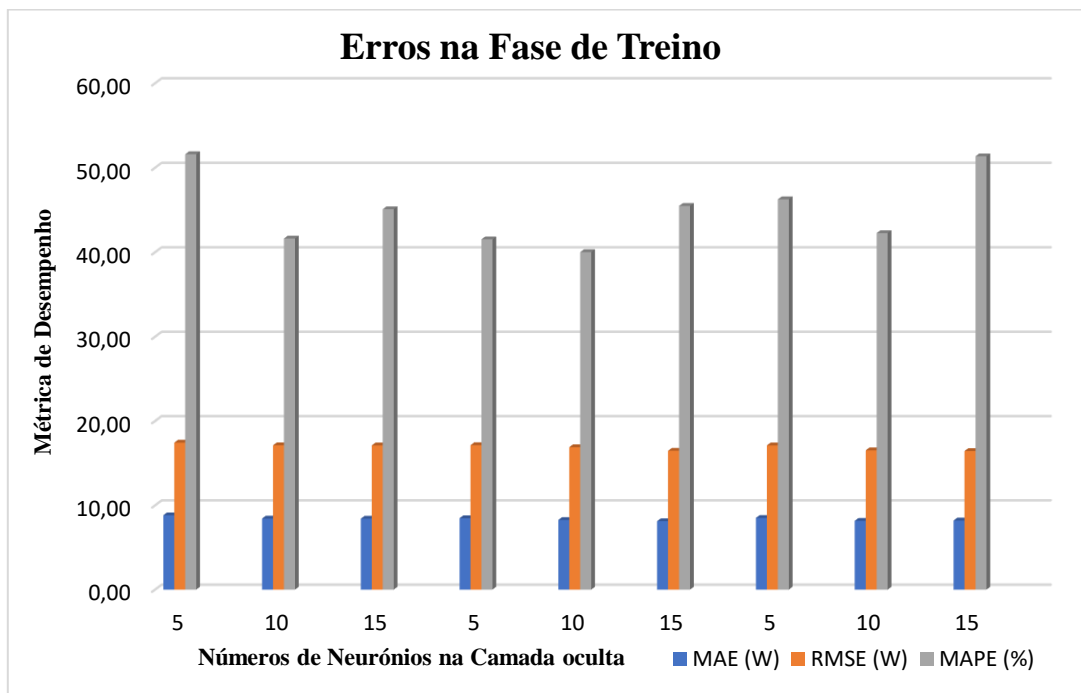


Figura 4.8 – Gráfico de métricas de desempenho na fase de Treino.

Para fase de validação os resultados das métricas de desempenho obtidas nessa etapa, são apresentados na Tabela 4.6.

Tabela 4.6 - Erros de previsão na fase de validação para as nove configurações.

Configuração da Camada Oculta	Função de Ativação	Neurónios por Camada oculta	MAE (W)	RSME (W)	MAPE(%)
1	Tanh-Sig	5	8,87	7,15	51,07
1	Tanh-Sig	10	8,26	6,58	43,31
1	Tanh-Sig	15	8,23	6,70	44,84
2	Tanh-Sig	5	8,65	6,56	43,05
2	Tanh-Sig	10	8,51	6,32	39,93
2	Tanh-Sig	15	8,20	6,67	44,53
3	Tanh-Sig	5	8,83	6,92	47,88
3	Tanh-Sig	10	8,31	6,61	43,72
3	Tanh-Sig	15	8,38	7,23	52,28

Durante a fase de validação do modelo, observou-se um comportamento das métricas de desempenho semelhante ao da fase anterior. Os valores dos erros percentuais absolutos oscilaram entre 39% e quase 52%, com a configuração de duas camadas ocultas e 10 neurónios a apresentar o menor erro nesta etapa, como ilustra a Figura 4.9.




Figura 4.9 – Gráfico de métrica de desempenhos na fase de validação.

Com base no que foi discutido, seguem-se os gráficos de regressão para as melhores configurações nas fases de Treino e validação. Nestes gráficos, são apresentados os coeficientes de correlação correspondentes e as curvas de ajuste. Tal como detalhado anteriormente na Figura 4.7, a mesma abordagem foi aplicada nestas duas figuras para compreender a relação em questão.

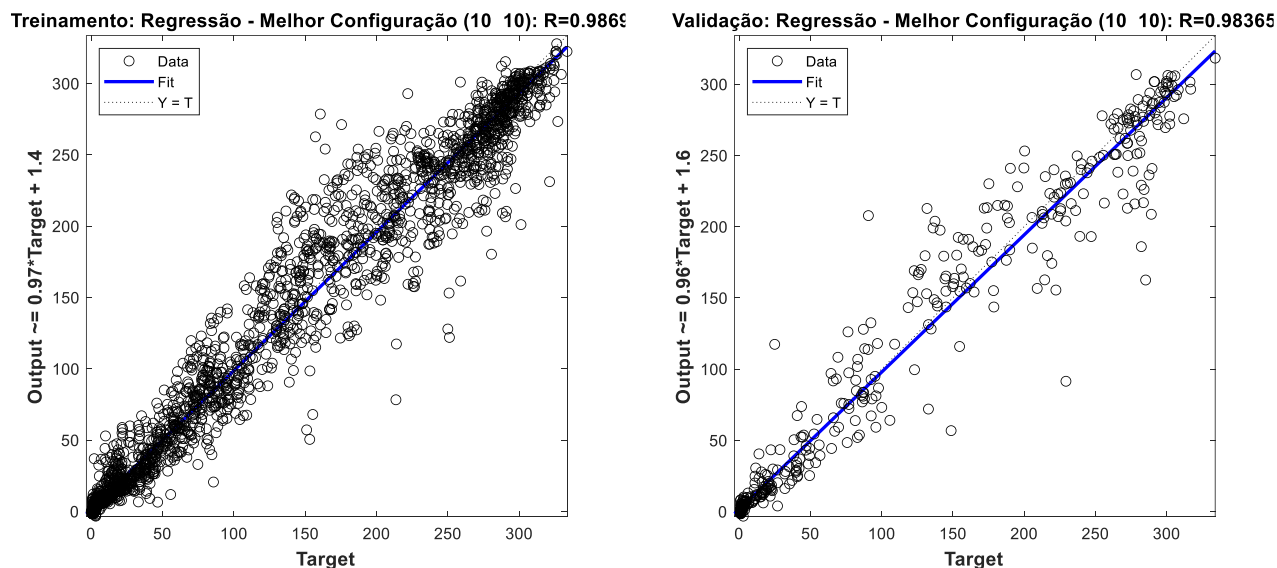


Figura 4.10 – Gráficos de regressão das melhores configurações nas fases de Treino e validação.

Após identificar a melhor configuração da rede neuronal artificial nas etapas de treino e validação, foram efetuadas previsões preliminares com os mesmos dados utilizados anteriormente. O intuito foi comparar os valores previstos com os reais, para avaliar a precisão do modelo nestas fases. A análise do gráfico sugere uma concordância razoável entre os valores previstos e os reais, com algumas pequenas discrepâncias, onde em certos momentos os valores reais superaram ligeiramente as previsões. A Figura 4.11, ilustra os resultados dessas comparações.




Figura 4.11- Gráficos de previsão de produção de energia solar fotovoltaica na fase de previsão e validação.

4.5 Apresentação dos Resultados e Análise Comparativa

Nesta etapa, serão apresentados os resultados dos testes de previsão da produção de energia solar fotovoltaica utilizando os dados previamente reservados para essa finalidade. Com a melhor configuração do modelo determinada nas fases anteriores, foram realizadas previsões com horizonte de uma hora, para períodos de um dia, especificamente nos dias 2 e 3 de novembro, assim como nos dias 1 e 2 de dezembro. Para esses testes, foram empregados dados de irradiância e temperatura que não haviam sido utilizados durante o treino e a validação, que serviram como entradas para o modelo, com o objetivo de efetuar a previsão de potência gerada nesses dias e compará-la com os valores efetivamente medidos.

Na Tabela 4.7, estão apresentados os valores reais e previstos da produção de potência solar fotovoltaica referentes ao dia 2 de novembro de 2013, juntamente com os erros absolutos e percentuais absolutos correspondentes.

Tabela 4.7 – Valores de potência real e prevista na fase de teste para o dia 2 de novembro.

Tempo	Potência Real (W)	Potência Prevista (W)	AE (W)	APE (%)
00:00:00	0,83	0,73	0,10	14,26
01:00:00	0,83	0,76	0,07	9,57
02:00:00	0,84	0,81	0,03	3,40
03:00:00	0,85	0,90	0,05	5,50
04:00:00	0,83	0,96	0,13	13,97
05:00:00	0,85	1,01	0,16	15,52
06:00:00	0,85	0,99	0,14	14,07
07:00:00	2,29	1,05	1,24	117,24
08:00:00	10,69	3,81	6,88	180,90
09:00:00	19,79	10,06	9,73	96,67
10:00:00	46,34	16,65	29,69	178,33
11:00:00	99,50	35,81	63,69	177,87
12:00:00	235,13	76,21	158,92	208,53
13:00:00	212,37	178,09	34,28	19,25
14:00:00	83,02	160,49	77,47	48,27
15:00:00	141,21	54,32	86,89	159,95
16:00:00	72,60	92,79	20,19	21,76
17:00:00	4,97	29,84	24,87	83,34
18:00:00	0,83	5,00	4,17	83,40
19:00:00	0,83	0,65	0,18	28,28
20:00:00	0,84	0,66	0,18	28,06
21:00:00	0,83	0,63	0,20	31,99
22:00:00	0,80	0,65	0,15	22,51
23:00:00	0,83	0,56	0,27	48,55

A Figura 4.12 mostra graficamente a comparação entre os valores da potência real e os valores previstos para o dia 2 de novembro de 2013.




Figura 4.12 – Previsão de energia solar fotovoltaica no dia 2 de novembro de 2013.

Ao analisar a Figura 4.12, que faz a comparação entre os valores médios reais e previstos da produção de energia fotovoltaica para o dia 2 de novembro de 2013, verifica-se uma variação de produção entre 0 a quase 250 watts, com os valores reais geralmente superiores aos previstos ao longo do dia. A semelhança entre os padrões de variação, com níveis baixos no início e fim do dia e valores mais elevados ao meio, é evidente, mas nota-se que as maiores diferenças entre as previsões e os valores reais ocorrem entre as 11h e as 15h. No entanto, em torno das 14h, 16h e 17h, as previsões superam os valores reais, evidenciando pequenas discrepâncias no modelo de previsão.

Os resultados da previsão de energia FV na fase de teste, conforme as métricas de desempenho para o horizonte de uma hora adotadas neste estudo, encontram-se detalhados na Tabela 4.8.

Tabela 4.8 – Resultados das métricas de desempenho na fase de previsão no dia 2 de novembro

Modelo	MAE (W)	RMSE (W)	MAPE (%)
ANN	21,65	43,83	67,13

Na tabela a seguir, estão expostos os resultados das previsões realizadas para o dia 3 de novembro do ano em análise, onde é possível observar os valores de potência real e prevista, juntamente com os respectivos erros absolutos e percentuais.

Tabela 4.9 - Valores de potência real e prevista na fase de teste para o dia 3 de novembro.

Tempo	Potência Real (W)	Potência Prevista (W)	AE (W)	APE (%)
00:00:00	0,80	0,57	0,23	41,51
01:00:00	0,78	0,71	0,07	9,83
02:00:00	0,81	0,83	0,02	2,40
03:00:00	0,82	0,82	0,00	0,15
04:00:00	0,82	0,83	0,01	1,70
05:00:00	0,78	0,94	0,16	17,32
06:00:00	0,81	0,89	0,08	9,24
07:00:00	3,64	0,95	2,69	281,78
08:00:00	38,17	4,68	33,49	715,65
09:00:00	92,40	31,54	60,86	192,92
10:00:00	212,01	59,30	152,71	257,49
11:00:00	238,71	143,61	95,10	66,22
12:00:00	144,55	185,21	40,66	21,95
13:00:00	186,93	113,04	73,89	65,37
14:00:00	211,20	137,53	73,67	53,57
15:00:00	133,05	143,83	10,78	7,50
16:00:00	52,69	74,00	21,31	28,80
17:00:00	4,38	23,16	18,78	81,09
18:00:00	0,83	0,66	0,17	26,53
19:00:00	0,84	0,57	0,27	48,59
20:00:00	0,84	0,55	0,29	53,06
21:00:00	0,83	0,49	0,34	67,94
22:00:00	0,84	0,54	0,30	55,92
23:00:00	0,84	0,54	0,30	54,95

Através da Figura 4.13 é possível observar a comparação entre os valores de produção de potência que foram medida e previstas neste respectivo dia.




Figura 4.13 - Previsão de energia solar fotovoltaica no dia 3 de novembro de 2013.

Ao examinar a Figura 4.10, que compara os valores médios de produção real e previstos da potência fotovoltaica no dia 3 de novembro do ano em estudo, constata-se que a variação da potência vai de 0 W a quase 250 W. Observa-se que, nas primeiras horas de irradiação, os valores reais de produção superam os previstos, atingindo o pico às 11h, com a maior diferença entre as potências registrada às 10h. No entanto, a partir desse momento, a diferença entre os valores diminui, sendo que os valores previstos ultrapassam os reais às 12h, 15h, 16h e 17h.

Os resultados referentes à previsão de energia FV neste dia, com base nas métricas de desempenho utilizadas para o horizonte temporal de uma hora, estão apresentados de forma detalhada na Tabela 4.10.

Tabela 4.10 - Resultados das métricas de desempenho na fase de previsão no dia 3 de novembro

Modelo	MAE (W)	RMSE (W)	MAPE (%)
ANN	24,42	45,94	41,71

Na Tabela 4.11, encontram-se os resultados das previsões efetuadas para o dia 1 de dezembro de 2013, onde se podem observar os valores de potência real e prevista, bem como os respectivos erros absolutos e percentuais.

Tabela 4.11 - Valores de potência real e prevista na fase de teste para o dia 1 de dezembro.

Tempo	Potência Real (W)	Potência Prevista (W)	AE (W)	APE (%)
00:00:00	0,80	1,36	0,56	41,21
01:00:00	0,81	1,33	0,52	38,91
02:00:00	0,82	1,30	0,48	37,04
03:00:00	0,82	1,38	0,56	40,45
04:00:00	0,82	1,42	0,60	42,20
05:00:00	0,82	1,41	0,59	41,97
06:00:00	0,82	1,37	0,55	40,33
07:00:00	0,95	2,54	1,59	62,57
08:00:00	8,16	19,11	10,95	57,29
09:00:00	98,54	70,64	27,90	39,50
10:00:00	185,91	171,99	13,92	8,09
11:00:00	228,66	231,36	2,70	1,17
12:00:00	243,59	234,44	9,15	3,90
13:00:00	224,73	209,47	15,26	7,29
14:00:00	176,49	166,25	10,24	6,16
15:00:00	125,48	89,96	35,52	39,48
16:00:00	47,82	27,82	20,00	71,92
17:00:00	1,46	2,02	0,56	27,75
18:00:00	0,80	1,25	0,45	35,76
19:00:00	0,81	1,26	0,45	35,81
20:00:00	0,81	1,24	0,43	34,84
21:00:00	0,80	1,30	0,50	38,41
22:00:00	0,79	1,38	0,59	42,86
23:00:00	0,80	1,42	0,62	43,57

Na Figura 4.14, é possível visualizar a comparação entre os valores de produção de potência medidos e os valores previstos para este dia específico.




Figura 4.14 - Previsão de energia solar fotovoltaica no dia 1 de dezembro de 2013.

Ao observar a Figura 4.14, que compara os valores médios medidos e previstos da produção fotovoltaica no dia 1 de dezembro de 2013, nota-se uma variação entre 0 e cerca de 2500 W, com os valores reais a superarem os previstos na maior parte do dia. Este comportamento segue um padrão semelhante ao dos dias anteriores, onde ambos os valores apresentam comportamentos parecidos: níveis mais baixos nas primeiras e últimas horas, e picos no meio do período. A produção aumenta de forma gradual a partir das 8h, atingindo o máximo por volta do meio-dia, antes de começar a diminuir até às 16h. No entanto, as diferenças entre os valores reais e previstos não são muito acentuadas, destacando-se maiores discrepâncias entre as 9h, 15h e 16h, enquanto o valor previsto supera o real às 8h e mostram uma leve diferença às 11h.

A tabela seguinte apresenta os resultados dos erros médios referentes a previsão no dia em análise.

Tabela 4.12 - Resultados das métricas de desempenho na fase de previsão no dia 1 de dezembro

Modelo	MAE (W)	RMSE (W)	MAPE (%)
ANN	6,45	11,52	34,94

Finalmente, os resultados da previsão para o dia 2 de dezembro do ano em análise estão apresentados na Tabela 4.13, onde são exibidos os valores reais e previstos de produção, juntamente com os erros absolutos e percentuais correspondentes.

Tabela 4.13 - Valores de potência real e prevista na fase de teste para o dia 2 de dezembro.

Tempo	Potência Real (W)	Potência Prevista (W)	AE (W)	APE (%)
00:00:00	0,81	1,39	0,58	41,65
01:00:00	0,82	1,32	0,50	37,85
02:00:00	0,80	1,26	0,46	36,45
03:00:00	0,79	1,13	0,34	29,93
04:00:00	0,79	1,05	0,26	24,63
05:00:00	0,80	0,86	0,06	6,88
06:00:00	0,80	0,53	0,27	51,43
07:00:00	0,94	1,00	0,06	5,89
08:00:00	8,35	11,65	3,30	28,32
09:00:00	94,38	57,40	36,98	64,43
10:00:00	179,50	162,12	17,38	10,72
11:00:00	220,75	220,28	0,47	0,21
12:00:00	234,82	228,86	5,96	2,60
13:00:00	218,12	211,28	6,84	3,24
14:00:00	170,95	161,45	9,50	5,88
15:00:00	119,86	86,19	33,67	39,07
16:00:00	44,77	25,83	18,94	73,34
17:00:00	1,30	1,86	0,56	29,94
18:00:00	0,77	1,21	0,44	36,37
19:00:00	0,80	1,29	0,49	37,87
20:00:00	0,81	1,30	0,49	37,81
21:00:00	0,81	1,34	0,53	39,70
22:00:00	0,81	1,41	0,60	42,70
23:00:00	0,81	1,42	0,61	42,88

A Figura 4.15, mostra graficamente a comparação entre os valores da potência real e os valores previstos para o dia 2 de dezembro de 2013.

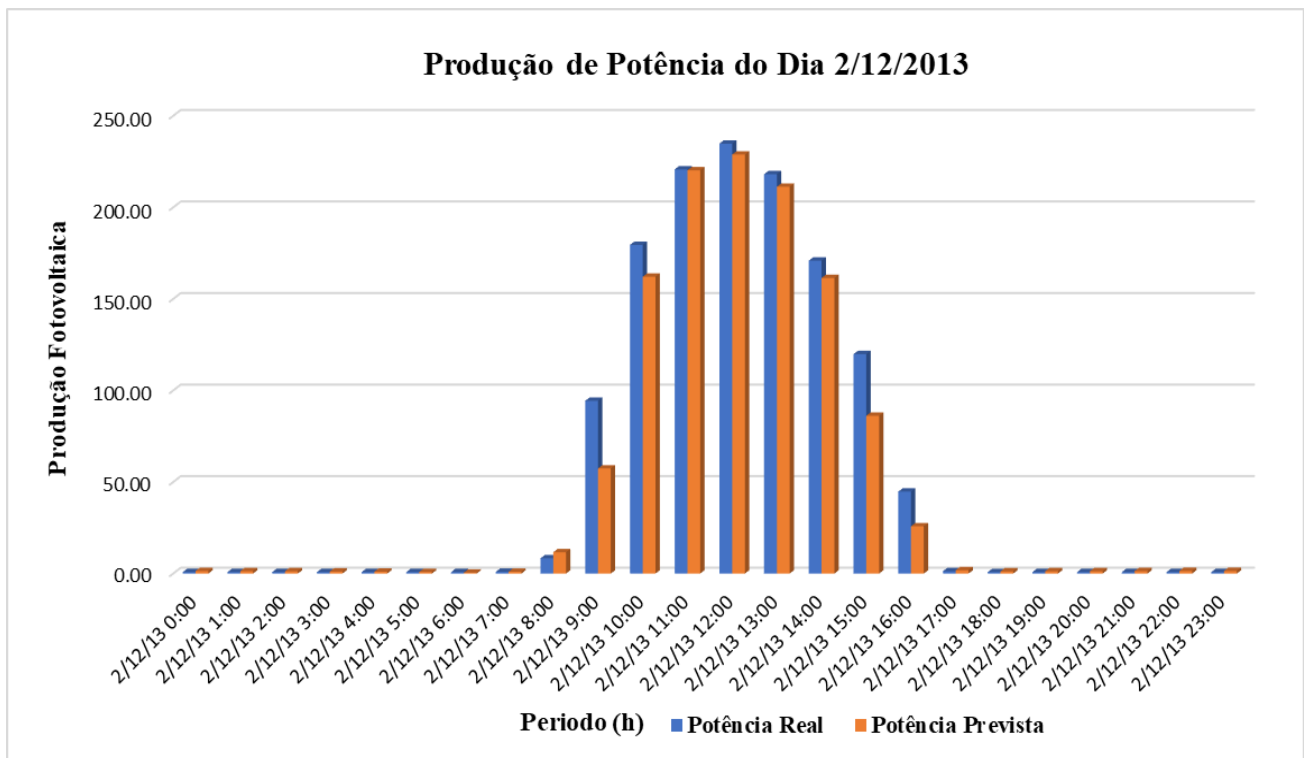


Figura 4.15 - Previsão de energia solar fotovoltaica no dia 2 de dezembro de 2013.

Seguindo a mesma lógica das análises anteriores, foi realizada uma análise a Figura 4.15, que diz respeito à previsão da produção fotovoltaica para o dia 2 de dezembro do ano de 2013. O gráfico revela semelhanças com o dia anterior, com a produção a oscilar entre 0 W e quase 250 W. Tal como nos outros dias, os valores de potência são praticamente nulos nas primeiras e últimas horas, começando a crescer a partir das 8h. É notável que, no início do dia, o valor previsto supera o real, embora com uma diferença ligeira; no entanto, ao longo do dia, os valores reais mantêm-se minimamente superiores. Às 11h, o valor real e previsto coincidem, enquanto entre as 12h e as 13h as diferenças são mínimas.

Os resultados da previsão de energia FV na fase de teste, conforme as métricas de desempenho para o horizonte de uma hora adotadas neste estudo, encontram-se detalhados na Tabela 4.14

Tabela 4.14 - Resultados das métricas de desempenho na fase de previsão no dia 2 de dezembro

Modelo	MAE (W)	RMSE (W)	MAPE (%)
ANN	5,80	11,81	30,41

Na tabela seguinte, é apresentada uma compilação dos erros registados durante a fase de testes, considerando as previsões realizadas ao longo dos quatro dias correspondentes aos dois últimos meses do ano de 2013.

Tabela 4.15 – Comparação dos resultados das métricas de desempenho na fase de teste

Médias das métricas de desempenho	Dias seleccionados para os testes de previsão			
	Dia 2 de novembro	Dia 3 de novembro	Dia 1 de dezembro	Dia 2 de dezembro
MAE	21,65	24,42	6,45	5,80
RMSE	43,83	45,94	11,52	11,81
MAPE	67,13	41,71	34,94	30,41

Com base na análise da tabela apresentada, é possível concluir que o modelo de previsão de energia solar fotovoltaica, que se utilizou a configuração otimizada identificada na fase de validação, demonstrou uma eficiência superior na previsão da potência solar nos dias 1 e 2 de dezembro, registando erros médios percentuais de 30,41% e 34,94%, superando os dias 2 e 3 de novembro. O modelo apresentou um desempenho razoável na fase de teste, com erros quase abaixo dos 50%. Diversos autores citados ao longo deste trabalho indicam que, quanto mais variáveis (como humidade, velocidade do vento e cobertura de nuvens) forem incorporadas como dados de entrada no modelo, maior será a precisão, uma vez que essas variáveis influenciam a produção fotovoltaica. A elevada taxa de erro nas previsões pode ser justificada pelo fato de apenas termos utilizado dois preditores (Irradiância e Temperatura), que são os principais na produção fotovoltaica, sem ter levado em consideração as outras variáveis mencionadas.

CONCLUSÕES E RECOMENDAÇÕES PARA TRABALHOS FUTUROS

5.1 Conclusões

A conclusão deste trabalho evidencia a importância crucial da previsão precisa da produção de energia solar fotovoltaica no contexto da crescente incorporação de fontes de energia renovável nos sistemas elétricos. Ao longo deste trabalho, foi possível observar que a adaptabilidade dos métodos de previsão às condições climáticas e características regionais é fundamental para melhorar a flexibilidade e a confiabilidade operacional da rede elétrica. A utilização de abordagens que combinam técnicas físicas, estatísticas e híbridas, aliada à implementação de modelos de inteligência artificial, revelou-se eficaz na captura das complexidades dos dados.

A análise do horizonte temporal das previsões demonstrou a relevância de alinhar a escolha do método às necessidades específicas do sistema energético, considerando as diferenças entre previsões de curto e longo prazo. Embora o modelo de previsão de curto prazo desenvolvido tenha mostrado um desempenho robusto, com um elevado coeficiente de correlação, a pesquisa também identificou a necessidade de melhorias contínuas e a consideração de múltiplas variáveis que influenciam a produção de energia solar.

Nesse sentido, é possível concluir que o modelo de previsão de energia solar fotovoltaica, que utilizou a configuração otimizada identificada na fase de validação, demonstrou uma eficiência superior na previsão da potência solar nos dias 1 e 2 de dezembro, registrando erros médios percentuais de 30,41% e 34,94%, respectivamente, superando os erros observados nos dias 2 e 3 de novembro. O modelo apresentou um desempenho razoável na fase de teste, com erros quase abaixo dos 50%. A literatura revisada ao longo deste trabalho indica que a inclusão de mais variáveis, como umidade, velocidade do vento e cobertura de nuvens, poderia aumentar a precisão das previsões, uma vez que esses fatores influenciam diretamente a pro-

dução fotovoltaica. A elevada taxa de erro nas previsões pode ser justificada pelo fato de que apenas dois preditores (irradiância e temperatura) foram utilizados como dados de entrada no modelo, sem levar em consideração as outras variáveis mencionadas.

Em síntese, o estudo reforça a necessidade de evolução constante nas técnicas de previsão e a importância da integração de diferentes abordagens para enfrentar os desafios futuros. A colaboração entre ciência, tecnologia e práticas operacionais será essencial para garantir que as previsões de produção de energia solar fotovoltaica se mantenham precisas e confiáveis, contribuindo para a sustentabilidade e resiliência dos sistemas elétricos do amanhã.

5.2 Recomendações Para Trabalhos Futuros

Com base no estudo realizado, várias recomendações podem ser feitas para trabalhos futuros na área de previsão de produção de energia solar fotovoltaica. Estas recomendações visam aprimorar a precisão dos modelos de previsão, otimizar o uso de dados e enfrentar os desafios associados à variabilidade climática. Aqui estão algumas sugestões:

- **Exploração de Modelos Híbridos:** Recomenda-se a exploração de modelos híbridos para melhorar a precisão das previsões e adaptar-se melhor às variáveis climáticas.
- **Incorporação de Dados Adicionais:** Melhore a precisão das previsões ao incluir novas variáveis de entrada como umidade, velocidade do vento.
- **Consideração de Variações Regionais:** Adapte os modelos às características climáticas específicas de cada região para melhorar a precisão das previsões.
- **Desenvolvimento de Modelos para Diferentes Horizontes Temporais:** Aplique modelos que cobrem desde previsões de curto prazo até previsões de longo prazo para atender a diversas necessidades operacionais e de planejamento.
- **Aplicação de Técnicas Avançadas de IA:** Use técnicas avançadas de inteligência artificial, como redes neurais profundas (DeepLearnig) e algoritmos de aprendizado de máquina sofisticados, para identificar padrões complexos e responder rapidamente a mudanças climáticas.

Bibliografia

- Agoua, X. G., Girard, R., & Kariniotakis, G. (2018). Short-Term Spatio-Temporal Forecasting of Photovoltaic Power Production. *IEEE Transactions on Sustainable Energy*, 9(2), 538–546. <https://doi.org/10.1109/TSTE.2017.2747765>
- Águia, D. V. A. (2016). *Previsão de produção solar fotovoltaica através do modelo elétrico*. Faculdade de Engenharia da Universidade do Porto.
- Ahmed, A., & Khalid, M. (2019). A review on the selected applications of forecasting models in renewable power systems. *Renewable and Sustainable Energy Reviews*, 100, 9–21. <https://doi.org/10.1016/J.RSER.2018.09.046>
- Ahmed, R., Sreeram, V., Mishra, Y., & Arif, M. D. (2020). A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization. In *Renewable and Sustainable Energy Reviews* (Vol. 124). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2020.109792>
- AIE. (2020). *Agencia Internacional de Energía*. Ponga La Energía Limpia En El Centro de Los Planes de Estímulo Para Contrarrestar La Crisis Del Coronavirus.
- Akhter, M. N., Mekhilef, S., Mokhlis, H., & Shah, N. M. (2019). Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques. In *IET Renewable Power Generation* (Vol. 13, Issue 7, pp. 1009–1023). Institution of Engineering and Technology. <https://doi.org/10.1049/iet-rpg.2018.5649>
- Alipour, M., Aghaei, J., Norouzi, M., Niknam, T., Hashemi, S., & Lehtonen, M. (2020). A novel electrical net-load forecasting model based on deep neural networks and wavelet transform integration. *Energy*, 205. <https://doi.org/10.1016/j.energy.2020.118106>
- Alonso-Montesinos, J., Batlles, F. J., & Portillo, C. (2015). Solar irradiance forecasting at one-minute intervals for different sky conditions using sky camera images. *Energy Conversion and Management*, 105, 1166–1177. <https://doi.org/10.1016/j.enconman.2015.09.001>
- Antonanzas, J., Osorio, N., Escobar, R., Urraca, R., Martinez-de-Pison, F. J., & Antonanzas-Torres, F. (2016). Review of photovoltaic power forecasting. *Solar Energy*, 136, 78–111. <https://doi.org/10.1016/J.SOLENER.2016.06.069>
- Anuradha, K., Erlapally, D., Karuna, G., Srilakshmi, V., & Adilakshmi, K. (2021). Analysis Of Solar Power Generation Forecasting Using Machine Learning Techniques. *E3S Web of Conferences*, 309. <https://doi.org/10.1051/e3sconf/202130901163>

- Azimi, R., Ghayekhloo, M., & Ghofrani, M. (2016). A hybrid method based on a new clustering technique and multilayer perceptron neural networks for hourly solar radiation forecasting. *Energy Conversion and Management*, *118*, 331–344. <https://doi.org/10.1016/j.enconman.2016.04.009>
- Babatunde, O. M., Munda, J. L., Hamam, Y., & Monyei, C. G. (2023). A critical overview of the (Im)practicability of solar radiation forecasting models. *E-Prime - Advances in Electrical Engineering, Electronics and Energy*, *5*. <https://doi.org/10.1016/j.prime.2023.100213>
- Bazonis, I. K., Kousounadis-Knousen, M. A., Georgilakis, P. S., Shirazi, E., Soudris, D., & Catthoor, F. (2023). A taxonomy of short-term solar power forecasting: Classifications focused on climatic conditions and input data. In *IET Renewable Power Generation* (Vol. 17, Issue 9, pp. 2411–2432). John Wiley and Sons Inc. <https://doi.org/10.1049/rpg2.12736>
- Bizzarri, F., Bongiorno, M., Brambilla, A., Gruosso, G., & Gajani, G. S. (2013). Model of photovoltaic power plants for performance analysis and production forecast. *IEEE Transactions on Sustainable Energy*, *4*(2), 278–285. <https://doi.org/10.1109/TSTE.2012.2219563>
- Blanc, P., Remund, J., & Vallance, L. (2017). Short-term solar power forecasting based on satellite images. *Renewable Energy Forecasting: From Models to Applications*, 179–198. <https://doi.org/10.1016/B978-0-08-100504-0.00006-8>
- Castro, R. (2018). *Uma Introdução às Energias Renováveis: Eólica, Fotovoltáica e Mini-Hídrica* (Catro Rui, Ed.; 3ª Edição, Vol. 3). IST Press.
- Chatzipanagi, A., & Jäger-Waldau, A. (2023). The European Solar Communication—Will It Pave the Road to Achieve 1 TW of Photovoltaic System Capacity in the European Union by 2030? *Sustainability (Switzerland)*, *15*(8). <https://doi.org/10.3390/su15086531>
- Chen, S. X., Gooi, H. B., & Wang, M. Q. (2013). Solar radiation forecast based on fuzzy logic and neural networks. *Renewable Energy*, *60*, 195–201. <https://doi.org/10.1016/j.renene.2013.05.011>
- Chu, Y., Urquhart, B., Gohari, S. M. I., Pedro, H. T. C., Kleissl, J., & Coimbra, C. F. M. (2015). Short-term reforecasting of power output from a 48 MWe solar PV plant. *Solar Energy*, *112*, 68–77. <https://doi.org/10.1016/j.solener.2014.11.017>
- Coimbra, C. F. M., Kleissl, J., & Marquez, R. (2013). Overview of Solar-Forecasting Methods and a Metric for Accuracy Evaluation. In *Solar Energy Forecasting and Resource Assessment* (pp. 171–194). Elsevier Inc. <https://doi.org/10.1016/B978-0-12-397177-7.00008-5>

- Cornaro, C., Pierro, M., & Bucci, F. (2015). Master optimization process based on neural networks ensemble for 24-h solar irradiance forecast. *Solar Energy*, *111*, 297–312. <https://doi.org/10.1016/J.SOLENER.2014.10.036>
- Dong, Z., Yang, D., Reindl, T., & Walsh, W. M. (2014). Satellite image analysis and a hybrid ESSS/ANN model to forecast solar irradiance in the tropics. *Energy Conversion and Management*, *79*, 66–73. <https://doi.org/10.1016/j.enconman.2013.11.043>
- Dutta, S., Li, Y., Venkataraman, A., Costa, L. M., Jiang, T., Plana, R., Tordjman, P., Choo, F. H., Foo, C. F., & Puttgen, H. B. (2017). Load and Renewable Energy Forecasting for a Microgrid using Persistence Technique. *Energy Procedia*, *143*, 617–622. <https://doi.org/10.1016/j.egypro.2017.12.736>
- Ekici, B. B. (2014). A least squares support vector machine model for prediction of the next day solar insolation for effective use of PV systems. *Measurement: Journal of the International Measurement Confederation*, *50*(1), 255–262. <https://doi.org/10.1016/j.measurement.2014.01.010>
- El Hendouzi, A., & Bourouhou, A. (2020). Solar Photovoltaic Power Forecasting. In *Journal of Electrical and Computer Engineering* (Vol. 2020). Hindawi Limited. <https://doi.org/10.1155/2020/8819925>
- Feng, J., & Xu, S. X. (2021). Integrated technical paradigm based novel approach towards photovoltaic power generation technology. *Energy Strategy Reviews*, *34*, 100613. <https://doi.org/10.1016/J.ESR.2020.100613>
- Fernandez-Jimenez, L. A., Muñoz-Jimenez, A., Falces, A., Mendoza-Villena, M., Garcia-Garrido, E., Lara-Santillan, P. M., Zorzano-Alba, E., & Zorzano-Santamaria, P. J. (2012). Short-term power forecasting system for photovoltaic plants. *Renewable Energy*, *44*, 311–317. <https://doi.org/10.1016/j.renene.2012.01.108>
- FICHA TÉCNICA Título: Estatísticas rápidas das renováveis.* (n.d.).
- Gairaa, K., Khellaf, A., Messlem, Y., & Chellali, F. (2016). Estimation of the daily global solar radiation based on Box-Jenkins and ANN models: A combined approach. In *Renewable and Sustainable Energy Reviews* (Vol. 57, pp. 238–249). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2015.12.111>
- Gandoman, F. H., Raeisi, F., & Ahmadi, A. (2016). A literature review on estimating of PV-array hourly power under cloudy weather conditions. *Renewable and Sustainable Energy Reviews*, *63*, 579–592. <https://doi.org/10.1016/J.RSER.2016.05.027>
- Ghislain Agoua, X., Girard, R., Kariniotakis, G., & Kariniotakis, G. (2018). Photovoltaic Power Production. *IEEE Transactions on Sustainable Energy*, *9*(2). <https://doi.org/10.1109/TSTE.2017.2747765>

- Ghofrani, M., Ghayekhloo, M., & Azimi, R. (2016). A novel soft computing framework for solar radiation forecasting. *Applied Soft Computing Journal*, 48, 207–216. <https://doi.org/10.1016/j.asoc.2016.07.022>
- Grimaccia, F., Mussetta, M., & Zich, R. (2011). Neuro-Fuzzy Predictive Model for PV Energy Production based on Weather Forecast. *IEEE International Conference on Fuzzy Systems*, 1–4.
- Guermoui, M., Melgani, F., Gairaa, K., & Mekhalfi, M. L. (2020). A comprehensive review of hybrid models for solar radiation forecasting. In *Journal of Cleaner Production* (Vol. 258). Elsevier Ltd. <https://doi.org/10.1016/j.jclepro.2020.120357>
- Guleryuz, D. (2021). Forecasting outbreak of COVID-19 in Turkey; Comparison of Box–Jenkins, Brown’s exponential smoothing and long short-term memory models. *Process Safety and Environmental Protection*, 149, 927–935. <https://doi.org/10.1016/j.psep.2021.03.032>
- Haiges, R., Wang, Y. D., Ghoshray, A., & Roskilly, A. P. (2017). Forecasting Electricity Generation Capacity in Malaysia: An Auto Regressive Integrated Moving Average Approach. *Energy Procedia*, 105, 3471–3478. <https://doi.org/10.1016/j.egypro.2017.03.795>
- Hossain, M., Mekhilef, S., Danesh, M., Olatomiwa, L., & Shamshirband, S. (2017). Application of extreme learning machine for short term output power forecasting of three grid-connected PV systems. *Journal of Cleaner Production*, 167, 395–405. <https://doi.org/10.1016/j.jclepro.2017.08.081>
- Hossain, M. S., Ong, Z. C., Ismail, Z., Noroozi, S., & Khoo, S. Y. (2017). Artificial neural networks for vibration based inverse parametric identifications: A review. In *Applied Soft Computing Journal* (Vol. 52, pp. 203–219). Elsevier Ltd. <https://doi.org/10.1016/j.asoc.2016.12.014>
- Huang, G. Bin, Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1–3), 489–501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- HUANG, Y., LU, J., LIU, C., XU, X., WANG, W., & ZHOU, X. (2010). Comparative Study of Power Forecasting Methods for PV Stations. *2010 International Conference on Power System Technology*, 1–6.
- Ibrić, S., Djuriš, J., Parojčić, J., & Djurić, Z. (2012). Artificial neural networks in evaluation and optimization of modified release solid dosage forms. In *Pharmaceutics* (Vol. 4, Issue 4, pp. 531–550). <https://doi.org/10.3390/pharmaceutics4040531>
- Iheanetu, K. J. (2022). Solar Photovoltaic Power Forecasting: A Review. In *Sustainability (Switzerland)* (Vol. 14, Issue 24). MDPI. <https://doi.org/10.3390/su142417005>

- Ineichen, P., & Perez, R. (1999). Derivation of cloud index from geostationary satellites and application to the production of solar irradiance and daylight illuminance data. *Theoretical and Applied Climatology*, 64(1–2), 119–130. <https://doi.org/10.1007/S007040050116/METRICS>
- IRENA Renewable Energy Insights_Technologies | Tableau Public. (n.d.). Retrieved December 24, 2023, from <https://public.tableau.com/app/profile/irena.resource/viz/shared/YZDZRWHB4>
- Jäger-Waldau, A. (2023). Snapshot of Photovoltaics - May 2023. *EPJ Photovoltaics*, 14. <https://doi.org/10.1051/epjpv/2023016>
- Jamil, I., Lucheng, H., Iqbal, S., Aurangzaib, M., Jamil, R., Kotb, H., Alkuhayli, A., & Abo-Ras, K. M. (2023). Predictive evaluation of solar energy variables for a large-scale solar power plant based on triple deep learning forecast models. *Alexandria Engineering Journal*, 76, 51–73. <https://doi.org/10.1016/j.aej.2023.06.023>
- Johnsson, R. (2006). Cylinder pressure reconstruction based on complex radial basis function networks from vibration and speed signals. *Mechanical Systems and Signal Processing*, 20(8), 1923–1940. <https://doi.org/10.1016/j.ymsp.2005.09.003>
- Kannan, N., & Vakeesan, D. (2016). Solar energy for future world: - A review. In *Renewable and Sustainable Energy Reviews* (Vol. 62, pp. 1092–1105). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2016.05.022>
- Ledmaoui, Y., El Maghraoui, A., El Aroussi, M., Saadane, R., Chebak, A., & Chehri, A. (2023). Forecasting solar energy production: A comparative study of machine learning algorithms. *Energy Reports*, 10, 1004–1012. <https://doi.org/10.1016/j.egy.2023.07.042>
- Lim, S. C., Huh, J. H., Hong, S. H., Park, C. Y., & Kim, J. C. (2022). Solar Power Forecasting Using CNN-LSTM Hybrid Model. *Energies*, 15(21). <https://doi.org/10.3390/en15218233>
- Lima, S. D. (2014). *Previsão de Produção de Centrais Solares Fotovoltaicas*. FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO.
- Liu, C. H., Gu, J. C., & Yang, M. T. (2021). A Simplified LSTM Neural Networks for One Day-Ahead Solar Power Forecasting. *IEEE Access*, 9, 17174–17195. <https://doi.org/10.1109/ACCESS.2021.3053638>
- Liu, C., Li, M., Yu, Y., Wu, Z., Gong, H., & Cheng, F. (2022). A Review of Multitemporal and Multispatial Scales Photovoltaic Forecasting Methods. In *IEEE Access* (Vol. 10, pp. 35073–35093). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2022.3162206>

- Lorenz, E., & Heinemann, D. (2012). Prediction of Solar Irradiance and Photovoltaic Power. *Comprehensive Renewable Energy*, 239–292. <https://doi.org/10.1016/B978-0-08-087872-0.00114-1>
- Malki, H. A., Karayiannis, N. B., & Balasubramanian, M. (2004). Short-term electric power load forecasting using feedforward neural networks. *Expert Systems*, 21(3), 157–167. <https://doi.org/10.1111/j.1468-0394.2004.00272.x>
- Marquez, R., Pedro, H. T. C., & Coimbra, C. F. M. (2013). Hybrid solar forecasting method uses satellite imaging and ground telemetry as inputs to ANNs. *Solar Energy*, 92, 176–188. <https://doi.org/10.1016/j.solener.2013.02.023>
- Mathiesen, P., & Kleissl, J. (2011). Evaluation of numerical weather prediction for intra-day solar forecasting in the continental United States. *Solar Energy*, 85(5), 967–977. <https://doi.org/10.1016/j.solener.2011.02.013>
- Mellit, A., Benganem, M., Arab, A. H., & Guessoum, A. (2005). A simplified model for generating sequences of global solar radiation data for isolated sites: Using artificial neural network and a library of Markov transition matrices approach. *Solar Energy*, 79(5), 469–482. <https://doi.org/10.1016/j.solener.2004.12.006>
- Mohammadi, K., & Goudarzi, N. (2018). Study of inter-correlations of solar radiation, wind speed and precipitation under the influence of El Niño Southern Oscillation (ENSO) in California. *Renewable Energy*, 120, 190–200. <https://doi.org/10.1016/J.RENENE.2017.12.069>
- Mohammadi, K., Shamsirband, S., Tong, C. W., Arif, M., Petković, D., & Sudheer, C. (2015). A new hybrid support vector machine-wavelet transform approach for estimation of horizontal global solar radiation. *Energy Conversion and Management*, 92, 162–171. <https://doi.org/10.1016/j.enconman.2014.12.050>
- Mohandes, M. A. (2012). Modeling global solar radiation using Particle Swarm Optimization (PSO). *Solar Energy*, 86(11), 3137–3145. <https://doi.org/10.1016/j.solener.2012.08.005>
- Mohanty, S., & Kumar Patra, P. (2015). *Prediction of Global Solar Radiation using Nonlinear auto Regressive Network with Exogenous inputs (narx)*. 1–6.
- Monteiro, C., Fernandez-Jimenez, L. A., Ramirez-Rosado, I. J., Muñoz-Jimenez, A., & Lara-Santillan, P. M. (2013). Short-term forecasting models for photovoltaic plants: Analytical versus soft-computing techniques. *Mathematical Problems in Engineering*, 2013. <https://doi.org/10.1155/2013/767284>
- Morales-Aragonés, J. I., Dávila-Sacoto, M., González, L. G., Alonso-Gómez, V., Gallardo-Saavedra, S., & Hernández-Callejo, L. (2021). A review of I–V tracers for photovoltaic modules: Topologies and challenges. In *Electronics (Switzerland)* (Vol. 10, Issue 11). MDPI AG. <https://doi.org/10.3390/electronics10111283>

- Murugan, D. K., Said, Z., Panchal, H., Gupta, N. K., Subramani, S., Kumar, A., & Sadasivuni, K. K. (2023). Machine learning approaches for real-time forecasting of solar still distillate output. *Environmental Challenges*, *13*. <https://doi.org/10.1016/j.envc.2023.100779>
- Nespoli, A., Ogliari, E., Dolara, A., Grimaccia, F., Leva, S., & Mussetta, M. (2018). Validation of ANN Training Approaches for Day-Ahead Photovoltaic Forecasts. *IEEE*, 1–6.
- Notton, G., Paoli, C., Ivanova, L., Vasileva, S., & Nivet, M. L. (2013). Neural network approach to estimate 10-min solar global irradiation values on tilted planes. *Renewable Energy*, *50*, 576–584. <https://doi.org/10.1016/j.renene.2012.07.035>
- Observatório Da Energia, A. (n.d.). *Ficha Técnica Título Energia em Números-Edição 2023 Todos os direitos reservados. Publicação gratuita.*
- Olatomiwa, L., Mekhilef, S., Shamshirband, S., Mohammadi, K., Petković, D., & Sudheer, C. (2015). A support vector machine-firefly algorithm-based model for global solar radiation prediction. *Solar Energy*, *115*, 632–644. <https://doi.org/10.1016/j.solener.2015.03.015>
- Ostertagová, E., & Ostertag, O. (2013). Forecasting using simple exponential smoothing method. *Acta Electrotechnica et Informatica*, *12*(3). <https://doi.org/10.2478/v10198-012-0034-2>
- Patel, M. D., Shah, S., Sinha, S., Gupta, R. K., Bharti, S. K., & Singh, V. P. (2021). Solar Irradiation Forecasting - Comparative Analysis of Various Methods. *2021 IEEE International Conference on Technology, Research, and Innovation for Betterment of Society, TRIBES 2021*. <https://doi.org/10.1109/TRIBES52498.2021.9751626>
- Pelland, S., Galanis, G., & Kallos, G. (2013). Solar and photovoltaic forecasting through post-processing of the Global Environmental Multiscale numerical weather prediction model. *Progress in Photovoltaics: Research and Applications*, *21*(3), 284–296. <https://doi.org/10.1002/pip.1180>
- Perez, R., Kivalov, S., Schlemmer, J., Hemker, K., Renné, D., & Hoff, T. E. (2010). Validation of short and medium term operational solar radiation forecasts in the US. *Solar Energy*, *84*(12), 2161–2172. <https://doi.org/10.1016/J.SOLENER.2010.08.014>
- Poti, K. D., Naidoo, R. M., Mbungu, N. T., & Bansal, R. C. (2023). Intelligent solar photovoltaic power forecasting. *Energy Reports*, *9*, 343–352. <https://doi.org/10.1016/j.egy.2023.09.004>
- Rajagukguk, R. A., Kamil, R., & Lee, H.-J. (2021). *A Deep Learning Model to Forecast Solar Irradiance Using a Sky Camera*. <https://doi.org/10.3390/app>
- Ramli, M. A. M., Twaha, S., & Al-Turki, Y. A. (2015). Investigating the performance of support vector machine and artificial neural networks in predicting solar radiation on a tilted

- surface: Saudi Arabia case study. *Energy Conversion and Management*, 105, 442–452. <https://doi.org/10.1016/j.enconman.2015.07.083>
- Rodríguez, F., Martín, F., Fontán, L., & Galarza, A. (2021). Ensemble of machine learning and spatiotemporal parameters to forecast very short-term solar irradiation to compute photovoltaic generators' output power. *Energy*, 229. <https://doi.org/10.1016/j.energy.2021.120647>
- Rogado, A. R. B. (2019). *Sistema de Agregação de Dados Provenientes de Fontes de Energia Renováveis*. Faculdade de Ciência e Tecnologia da Universidade Nova de Lisboa.
- Salcedo-Sanz, S., Jiménez-Fernández, S., Aybar-Ruiz, A., Casanova-Mateo, C., Sanz-Justo, J., & García-Herrera, R. (2017). A CRO-species optimization scheme for robust global solar radiation statistical downscaling. *Renewable Energy*, 111, 63–76. <https://doi.org/10.1016/j.renene.2017.03.079>
- Sampaio, P. G. V., & González, M. O. A. (2017). Photovoltaic solar energy: Conceptual framework. In *Renewable and Sustainable Energy Reviews* (Vol. 74, pp. 590–601). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2017.02.081>
- Sbrana, G., & Silvestrini, A. (2014). Random switching exponential smoothing and inventory forecasting. *International Journal of Production Economics*, 156, 283–294. <https://doi.org/10.1016/J.IJPE.2014.06.016>
- Serrano, S. P. M. (2020). *Implementação de um sistema de previsão de produção fotovoltaica e consumos de um Edifício Inovador*. Universidade Nova de Lisboa - Faculdade de ciência e tecnologia .
- Shi, J., Lee, W. J., Liu, Y., Yang, Y., & Wang, P. (2012). Forecasting power output of photovoltaic systems based on weather classification and support vector machines. *IEEE Transactions on Industry Applications*, 48(3), 1064–1069. <https://doi.org/10.1109/TIA.2012.2190816>
- Silveira, J. L., Tuna, C. E., & Lamas, W. D. Q. (2013). The need of subsidy for the implementation of photovoltaic solar energy as supporting of decentralized electrical power generation in Brazil. *Renewable and Sustainable Energy Reviews*, 20, 133–141. <https://doi.org/10.1016/J.RSER.2012.11.054>
- Sobri, S., Koochi-Kamali, S., & Rahim, N. A. (2018). Solar photovoltaic generation forecasting methods: A review. In *Energy Conversion and Management* (Vol. 156, pp. 459–497). Elsevier Ltd. <https://doi.org/10.1016/j.enconman.2017.11.019>
- Subtil Lacerda, J., & Van Den Bergh, J. C. J. M. (2016). Diversity in solar photovoltaic energy: Implications for innovation and policy. *Renewable and Sustainable Energy Reviews*, 54, 331–340. <https://doi.org/10.1016/J.RSER.2015.10.032>

- Valente, M. Â. S. (2011). *Caracterização Automática de um Painel Fotovoltaico*. Universidade Nova de Lisboa Faculdade de Ciências e Tecnologia.
- Victoria, M., Haegel, N., Peters, I. M., Sinton, R., Jäger-Waldau, A., del Cañizo, C., Breyer, C., Stocks, M., Blakers, A., Kaizuka, I., Komoto, K., & Smets, A. (2021). Solar photovoltaics is ready to power a sustainable future. In *Joule* (Vol. 5, Issue 5, pp. 1041–1056). Cell Press. <https://doi.org/10.1016/j.joule.2021.03.005>
- Vignola, F., Michalsky, Joseph., & Stoffel, T. L. (2012). *Solar and infrared radiation measurements*. CRC Press.
- Voyant, C., Muselli, M., Paoli, C., & Nivet, M. L. (2012). Numerical weather prediction (NWP) and hybrid ARMA/ANN model to predict global radiation. *Energy*, 39(1), 341–355. <https://doi.org/10.1016/j.energy.2012.01.006>
- Wang, G., Su, Y., & Shu, L. (2016). One-day-ahead daily power forecasting of photovoltaic systems based on partial functional linear regression models. *Renewable Energy*, 96, 469–478. <https://doi.org/10.1016/J.RENENE.2016.04.089>
- Wu, Y. K., Huang, C. L., Phan, Q. T., & Li, Y. Y. (2022). Completed Review of Various Solar Power Forecasting Techniques Considering Different Viewpoints. In *Energies* (Vol. 15, Issue 9). MDPI. <https://doi.org/10.3390/en15093320>
- Xiao, W., Dunford, W. G., Palmer, P. R., & Capel, A. (2007). Regulation of photovoltaic voltage. *IEEE Transactions on Industrial Electronics*, 54(3), 1365–1374. <https://doi.org/10.1109/TIE.2007.893059>
- Yadav, A. P., & Behera, L. (2014). Solar radiation forecasting using neural networks and wavelet transform. *IFAC Proceedings Volumes (IFAC-PapersOnline)*, 3(PART 1), 890–896. <https://doi.org/10.3182/20140313-3-IN-3024.00218>
- Yang, B., Zhu, T., Cao, P., Guo, Z., Zeng, C., Li, D., Chen, Y., Ye, H., Shao, R., Shu, H., & Yu, T. (2023). Classification and Summarization of Solar Irradiance and Power Forecasting Methods: A Thorough Review. In *CSEE Journal of Power and Energy Systems* (Vol. 9, Issue 3, pp. 978–995). China Electric Power Research Institute. <https://doi.org/10.17775/CSEEJPES.2020.04930>
- Yang, D., Jirutitijaroen, P., & Walsh, W. M. (2012). Hourly solar irradiance time series forecasting using cloud cover index. *Solar Energy*, 86(12), 3531–3543. <https://doi.org/10.1016/j.solener.2012.07.029>
- Yang, H., Kurtz, B., Nguyen, D., Urquhart, B., Chow, C. W., Ghoniya, M., & Kleissl, J. (2014). Solar irradiance forecasting using a ground-based sky imager developed at UC San Diego. *Solar Energy*, 103, 502–524. <https://doi.org/10.1016/J.SOLENER.2014.02.044>

Zhou, H., Zhang, Y., Yang, L., Liu, Q., Yan, K., & Du, Y. (2019). Short-Term photovoltaic power forecasting based on long short term memory neural network and attention mechanism. *IEEE Access*, 7, 78063–78074. <https://doi.org/10.1109/ACCESS.2019.2923006>



