



**UNIVERSIDADE FEDERAL DO CEARÁ  
CENTRO DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**TATIANE CAROLYNE CARNEIRO**

**ESTRUTURA HÍBRIDA COMBINANDO *WAVELETS* E *RIDGE REGRESSION*  
*ENSEMBLE* DE MODELOS DE APRENDIZADO DE MÁQUINA APLICADOS À  
PREVISÃO SOLAR E EÓLICA NO BRASIL E NA ESPANHA**

**FORTALEZA**

**2023**

TATIANE CAROLYNE CARNEIRO

ESTRUTURA HÍBRIDA COMBINANDO *WAVELETS* E *RIDGE REGRESSION*  
*ENSEMBLE* DE MODELOS DE APRENDIZADO DE MÁQUINA APLICADOS À  
PREVISÃO SOLAR E EÓLICA NO BRASIL E NA ESPANHA

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Ceará, como requisito à obtenção do título de doutor em Engenharia Elétrica. Área de concentração: Energias Renováveis.

Orientador: Prof. Dr. Paulo Cesar Marques de Carvalho.

Coorientadores: Prof. Dr. Arthur Plínio de Souza Braga e Prof. Dr. Paulo Alexandre Costa Rocha.

FORTALEZA

2023

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

---

- C291e Carneiro, Tatiane.  
Estrutura Híbrida Combinando Wavelets e Ridge Regression Ensemble de Modelos de Aprendizado de Máquina Aplicados à Previsão Solar e Eólica no Brasil e na Espanha / Tatiane Carneiro. – 2023.  
215 f. : il. color.
- Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Fortaleza, 2023.  
Orientação: Prof. Dr. Paulo Cesar Marques de Carvalho.  
Coorientação: Prof. Dr. Arthur Plínio de Souza Braga e Prof Dr. Paulo Alexandre Costa Rocha.
1. Aprendizado de Máquina. 2. aprendizado profundo. 3. teoria do portfólio. 4. regressão penalizada. 5. recursos eólico e solar.. I. Título.

CDD 621.3

---

TATIANE CAROLYNE CARNEIRO

ESTRUTURA HÍBRIDA COMBINANDO *WAVELETS* E *RIDGE REGRESSION*  
*ENSEMBLE* DE MODELOS DE APRENDIZADO DE MÁQUINA APLICADOS À  
PREVISÃO SOLAR E EÓLICA NO BRASIL E NA ESPANHA

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Ceará, como requisito à obtenção do título de doutor em Engenharia Elétrica. Área de concentração: Energias Renováveis.

Aprovada em: 25/10/2023.

BANCA EXAMINADORA

---

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

---

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

---

Prof. Dr. Luis Miguel Fernández Ramírez  
Universidade de Cádiz (UCA)

---

Prof. Dr. Marcello Anderson Ferreira Batista Lima  
Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

---

Prof. Dr. Paulo Alexandre Costa Rocha  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Giovanni Cordeiro Barroso  
Universidade Federal do Ceará (UFC)

*Ao meu companheiro, Heron Alves dos Santos,  
aos meus pais, Francisca Francimar Costa e  
João Carneiro Sobrinho (in memoriam), à  
minha filha, Sofia Carlyne dos Santos, aos  
meus familiares e a todos os meus amigos.*

## AGRADECIMENTOS

A Deus, por sua caminhada junto a mim em todos os momentos.

Ao Prof. Dr. Paulo Cesar Marques de Carvalho, pela parceria, dedicação e orientação durante esses quatro anos de pesquisa na Universidade Federal do Ceará.

Aos Professores participantes da Banca examinadora Prof. Dr. Arthur Plínio de Souza Braga, Prof. Dr. Luis Miguel Fernández Ramírez, Prof. Dr. Marcello Anderson Ferreira Batista Lima, Prof. Dr. Giovanni Cordeiro Barroso e Prof. Dr. Paulo Alexandre Costa Rocha pelo tempo e pelas valiosas colaborações e sugestões.

Ao Prof. Dr. Paulo Alexandre Costa Rocha pelas excelentes contribuições que foram primordiais para o desenvolvimento dessa Tese.

Aos meus amigos, Marcelo Arruda, Elaine Farias, Pollyana Figueiredo, Isabel Cristina, Elisângela Maria e Gislane Pinho por estarem presentes em minha caminhada, me permitindo estar sempre mais perto de Deus.

À minha família, em especial ao meu companheiro, Heron Alves dos Santos, pela parceria e por estar sempre presente em minha vida.

Ao Prof. Dr. Camilo Allyson Simões de Farias pelos ensinamentos durante meu curso de graduação e até os dias atuais.

Aos colegas do doutorado, pelo companheirismo durante a minha caminhada.

A todos que, de uma maneira ou outra, contribuíram para o desenvolvimento desse trabalho de doutorado.

*“Energy and Persistence conquer all things”*  
(Benjamin Franklin)

## RESUMO

Nos últimos anos, com o rápido desenvolvimento da geração de eletricidade por meio das fontes eólica e solar, alguns problemas têm surgido gradativamente (incerteza e imprevisibilidade na geração final) e, muitas vezes, são inerentes à intermitência. Atualmente, um dos métodos essenciais para resolver esses problemas é a aplicação de metodologias de previsão. Esses métodos aprendem o comportamento das séries analisadas e implementam o conhecimento adquirido para prever valores futuros, podendo executar essa tarefa com metodologias individuais, por meio da combinação de diferentes metodologias (modelos híbridos) ou por meio da integração de diferentes resultados de modelos individuais (modelos de conjunto ou *ensemble*). Esta Tese propõe a aplicação de duas metodologias de conjunto/integração: a) *Ridge Regression Ensemble* (RRE); e b) Modelo híbrido que combina a decomposição de dados por meio da Transformada *Wavelet* (WT), modelos de Aprendizado de Máquina (AM) e o RRE (WD-RNA-RRE). Para comparação e validação dos desempenhos dos modelos propostos, o modelo de integração por meio da Teoria do Portfólio (PrevTP) também é aplicado. O objetivo das aplicações é integrar metodologias consolidadas de previsão eólica e solar aplicadas a dois locais com diferentes latitudes e perfis climáticos. A partir das simulações desenvolvidas (PrevTP, WD-RNA-RRE e RRE), as metodologias se mostraram eficientes para melhorarem o desempenho das previsões de métodos isolados e aplicáveis a diferentes localidades do mundo. Em termos de MAPE e RMSE, na aplicação aos dados solares e nas duas localidades, os modelos *ensemble* (WD-RNA-RRE e RRE) obtiveram melhor precisão que o melhor modelo *Cascade Forward Back Propagation* (CFBP) que teve melhor desempenho entre as aplicações individuais e que o modelo PrevTP. Nas aplicações aos dados eólicos, em termos de MAPE e RMSE, os modelos *ensemble* (WD-RNA-RRE, RRE e PrevTP) conseguiram melhorar o desempenho em relação aos modelos aplicados individualmente. Assim, pode-se destacar o PrevTP como a melhor aplicação aos dados espanhóis e o RRE com os melhores resultados na aplicação aos dados do Brasil. O PrevTP melhorou a precisão das metodologias individuais em duas das quatro aplicações desenvolvidas. As modelagens WD-RNA-RRE e RRE reduziram os erros de previsão em todas as aplicações e podem ser úteis na otimização do planejamento do uso de recursos solares e eólicos intermitentes nas matrizes elétricas.

**Palavras-chave:** Aprendizado de Máquina, aprendizado profundo, regressão penalizada, teoria do portfólio, recurso eólico, recurso solar.



## ABSTRACT

In recent years, with the rapid development of electricity generation through wind and solar sources, some problems have gradually emerged (uncertainty and unpredictability in the final generation) and are often inherent to intermittency. Currently, one of the essential methods to solve these problems is the application of forecasting methodologies. These methods learn the behavior of the analyzed series and implement the acquired knowledge to predict future values, being able to perform this task with individual methodologies, by combining different methodologies (hybrid models) or by integrating different results from individual models (ensemble models). This thesis proposes the application of two ensemble/integration methodologies: a) Ridge Regression Ensemble (RRE); and b) Hybrid model that combines data decomposition through the Wavelet Transform (WT), Machine Learning (AM) models and the RRE (WD-RNA-RRE). To compare and validate the performances of the proposed models, the model of integration through Portfolio Theory (PrevTP) is also applied. The objective of the applications is to integrate consolidated wind and solar forecasting methodologies applied to two locations with different latitudes and climate profiles. Based on the simulations developed (PrevTP, WD-RNA-RRE and RRE), the methodologies proved to be efficient in improving the forecasting performance of isolated methods and applicable to different locations around the world. In terms of MAPE and RMSE, in the application to solar data and in both locations, the ensemble models (WD-RNA-RRE and RRE) achieved better accuracy than the best *Cascade Forward Back Propagation* (CFBP), model that had the best performance among the individual applications, and than the PrevTP model. In the applications to wind data, in terms of MAPE and RMSE, the ensemble models (WD-RNA-RRE, RRE and PrevTP) managed to improve the performance in relation to the models applied individually. Thus, PrevTP can be highlighted as the best application to Spanish data and RRE with the best results in the application to data from Brazil. PrevTP improved the accuracy of individual methodologies in two of the four applications developed. The WD-RNA-RRE and RRE modeling reduced the forecast errors in all applications and can be useful in optimizing the planning of the use of intermittent solar and wind resources in the electric matrices.

**Keywords:** Machine learning, deep learning, penalized regression, portfolio theory, wind resource, solar resource.

## LISTA DE FIGURAS

Figura 2.1	Matriz Elétrica Brasileira 2023.....	38
Figura 2.2	Produtividade FV (kWh/kWp).....	39
Figura 2.3	Mapa temático de velocidade média anual para a altura de 150 metros.....	39
Figura 2.4	Matriz Elétrica da Espanha em 2023.....	40
Figura 2.5	Irradiação horizontal global na Espanha.....	41
Figura 2.6	Velocidade do vento, em m/s, na Espanha.....	42
Figura 3.1	Fase de planejamento do $qSLR$ .....	45
Figura 3.2	Informações gerais a respeito de artigos sobre previsão solar revisados por pares, publicados entre janeiro de 2015 e março de 2021: Autores.....	49
Figura 3.3	Informações gerais a respeito de artigos sobre previsão solar revisados por pares, publicados entre janeiro de 2015 e março de 2021: Coleção.....	49
Figura 3.4	Informações gerais a respeito de artigos sobre previsão solar revisados por pares, publicados entre janeiro de 2015 e março de 2021: Jornal.....	50
Figura 3.5	Informações gerais a respeito de artigos sobre previsão solar revisados por pares, publicados entre janeiro de 2015 e março de 2021: Continentes.....	50
Figura 3.6	Ano de surgimento das principais metodologias de previsão.....	70
Figura 3.7	Classificação dos métodos de previsão da geração FV e do recurso solar.....	71
Figura 3.8	Classificação de acordo com a abordagem de previsão.....	71
Figura 3.9	Classificação de acordo com o horizonte de previsão.....	72
Figura 3.10	Classificação de acordo com a meta de previsão.....	73
Figura 3.11	Classificação com base na escala espacial de previsão.....	73
Figura 3.12	Métricas de erro para avaliar a precisão dos métodos: a) determinísticas e b) probabilísticas.....	75
Figura 3.13	Informações gerais a respeito de artigos sobre previsão eólica revisados por pares, publicados entre janeiro de 2018 e março de 2023: Autores.....	82

Figura 3.14	Informações gerais a respeito de artigos sobre previsão eólica revisados por pares, publicados entre janeiro de 2018 e março de 2023: Coleção.....	82
Figura 3.15	Informações gerais a respeito de artigos sobre previsão eólica revisados por pares, publicados entre janeiro de 2018 e março de 2023: Jornal.....	83
Figura 3.16	Informações gerais a respeito de artigos sobre previsão eólica revisados por pares, publicados entre janeiro de 2018 e março de 2023: Continentes.....	83
Figura 3.17	Classificação dos métodos de previsão da geração e do recurso eólico.....	96
Figura 3.18	Classificação de acordo com a abordagem de previsão.....	96
Figura 3.19	Classificação de acordo com o horizonte de previsão.....	97
Figura 3.20	Classificação de acordo com a meta de previsão.....	97
Figura 3.21	Classificação com base na escala espacial de previsão.....	98
Figura 3.22	Métricas de erro para avaliar a precisão dos métodos: a) determinísticas e b) probabilísticas.....	99
Figura 4.1	Redução de variabilidade usando sistemas <i>ensemble</i> .....	105
Figura 4.2	<i>Ensemble</i> da classe paralela com n modelos individuais.....	106
Figura 5.1	Esquema para validação cruzada.....	113
Figura 5.2	Arquitetura MLP para previsão de recursos eólicos em Petrolina, Brasil.....	115
Figura 5.3	Arquitetura RBF utilizada para previsão de irradiância solar em Algeciras, Espanha.....	117
Figura 5.4	Arquitetura CFBP para previsão de recursos eólicos em Petrolina, Brasil.....	119
Figura 5.5	Arquitetura da SOM para previsão de irradiância solar e velocidade do vento em Algeciras (Espanha) (vetores 2 e 3, respectivamente) e Petrolina (Brasil) (vetores 1 e 4, respectivamente).....	122
Figura 5.6	Exemplo de fronteira eficiente entre ativos A e B.....	125
Figura 5.7	Arquiteturas: a) Estrutura da PrevTP; b) Estrutura simplificada da PrevTP. Ambas aplicadas a integração de previsões de velocidade do vento no Brasil.....	126

Figura 5.8	Arquiteturas: a) Estrutura da PrevTP; b) Estrutura simplificada da PrevTP. Ambas aplicadas a integração de previsões de velocidade do vento na Espanha.....	128
Figura 5.9	Arquiteturas: a) Estrutura da PrevTP; b) Estrutura simplificada da PrevTP. Ambas aplicadas a integração de previsões de irradiância solar no Brasil.....	129
Figura 5.10	Arquiteturas: a) Estrutura da PrevTP; b) Estrutura simplificada da PrevTP. Ambas aplicadas a integração de previsões de irradiância solar na Espanha.....	131
Figura 5.11	Estrutura da integração por meio do PrevTP.....	132
Figura 5.12	Estrutura da abordagem RRE proposta.....	133
Figura 5.13	Estrutura da abordagem híbrida proposta ( <i>WD – RNA – RRE</i> ).....	136
Figura 5.14	a) Esquema de decomposição; b) Previsão por modelos individuais; c) Reconstrução; e d) aplicação do <i>ensemble</i> proposto aos dados de vento nas duas localidades.....	140
Figura 6.1	Gráficos de correlação para MLP, RBF, CFPB e SOM, técnicas aplicadas individualmente para prever o recurso solar na Espanha.....	144
Figura 6.2	Correlações e frequências de ocorrência dos modelos <i>ensemble</i> (RRE, WD-RNA-RRE e PrevTP) para a previsão solar na Espanha.....	145
Figura 6.3	Ajuste de hiperparâmetros com validação cruzada para a previsão solar na Espanha.....	146
Figura 6.4	Contribuição de metodologias individuais em RRE para a previsão de recurso solar na Espanha.....	146
Figura 6.5	Dados solares observados e previstos dos métodos aplicados individualmente, RRE, WD-RNA-RRE e PrevTP na Espanha (janela de dados de 4 dias em 2009: 12 – 15/10 – excluindo horas noturnas).....	147
Figura 6.6	<i>Boxplot</i> da variação do erro de previsão solar na Espanha.....	148
Figura 6.7	Gráficos de correlação para MLP, RBF, CFPB e SOM, técnicas aplicadas individualmente para previsão do recurso solar no Brasil.....	149

Figura 6.8	Correlações e frequências de ocorrência para os resultados obtidos pelos modelos RRE, WD-RNA-RRE e PrevTP na previsão solar no Brasil.....	150
Figura 6.9	Ajuste de hiperparâmetros com validação cruzada para a previsão solar no Brasil.....	151
Figura 6.10	Contribuição das metodologias individuais no RRE para a previsão de recurso solar no Brasil.....	151
Figura 6.11	Dados solares observados e previstos dos métodos aplicados individualmente, do RRE, do WD-RNA-RRE e do PrevTP no Brasil (janela de 4 dias em 2015: 31/10 – 3/11 – excluindo horas noturnas).	152
Figura 6.12	<i>Boxplot</i> da variação do erro de previsão solar no Brasil.....	153
Figura 6.13	Gráficos de correlação para as técnicas MLP, RBF, CFPB e SOM aplicadas individualmente à previsão do vento na Espanha.....	155
Figura 6.14	Correlações e frequências de ocorrência para os resultados obtidos pelos modelos RRE, WD-RNA-RRE e PrevTP na previsão eólica na Espanha.....	155
Figura 6.15	Ajuste de hiperparâmetros com validação cruzada para a previsão do vento na Espanha.....	156
Figura 6.16	Contribuição de metodologias individuais em RRE para a previsão de recurso eólico na Espanha.....	156
Figura 6.17	Dados de vento observados e previstos dos métodos aplicados individualmente, RRE, WD-RNA-RRE e PrevTP na Espanha (janela de dados de 4 dias – 2009: 23 – 25/10).....	158
Figura 6.18	<i>Boxplot</i> da variação do erro de previsão do vento na Espanha.....	158
Figura 6.19	Gráficos de correlação para MLP, RBF, CFPB e SOM, técnicas aplicadas individualmente para previsão do recurso eólico no Brasil.....	160
Figura 6.20	Correlações e frequências de ocorrência para os resultados obtidos pelos modelos RRE, WD-RNA-RRE e PrevTP na previsão eólica no Brasil.....	160
Figura 6.21	Ajuste de hiperparâmetros com validação cruzada para previsão de vento no Brasil.....	161

Figura 6.22	Contribuição de metodologias individuais em RRE para a previsão de recurso eólico no Brasil.....	161
Figura 6.23	Dados de vento observados e previstos para os métodos aplicados individualmente, o RRE, o WD-RNA-RRE e o PrevTP no Brasil (janela de dados de 4 dias – 2009: 24 – 27/10) .....	163
Figura 6.24	<i>Boxplot</i> da variação dos erros de previsão de vento no Brasil.....	163

## LISTA DE TABELAS

Tabela 1.1	Resumo de alguns artigos da revisão de literatura.....	33
Tabela 3.1	Resumo das metodologias de previsão solar mais citadas.....	69
Tabela 3.2	Técnicas relevantes aplicadas aos horizontes de curto, médio e longo prazo e suas limitações.....	74
Tabela 3.3	Resumo das metodologias de previsão eólica mais citadas.....	95
Tabela 4.1	Resumo de abordagens corretivas usando previsão de séries temporais.....	109
Tabela 5.1	Locais, recursos, períodos e latitude e longitude usados na previsão.....	112
Tabela 5.2	Média dos erros na validação cruzada – recurso solar.....	114
Tabela 5.3	Média dos erros na validação cruzada – recurso eólico.....	114
Tabela 5.4	Resumo de erros e riscos calculados em todas as etapas da aplicação ao recurso eólico no Brasil.....	127
Tabela 5.5	Resumo de erros e riscos calculados em todas as etapas da aplicação ao recurso eólico na Espanha.....	129
Tabela 5.6	Resumo de erros e riscos calculados em todas as etapas da aplicação ao recurso solar no Brasil.....	130
Tabela 5.7	Resumo de erros e riscos calculados em todas as etapas da aplicação ao recurso solar na Espanha.....	132
Tabela 5.8	Testes desenvolvidos para a escolha do tipo de <i>Wavelet</i> e da quantidade de níveis a ser considerada nas aplicações aos dados eólicos e solares nas duas localidades.....	139
Tabela 6.1	Métricas para avaliar metodologias individuais, aplicação do RRE, WD-RNA-RRE e do PrevTP na Espanha.....	147
Tabela 6.2	Parâmetros de <i>boxplot</i> usados para avaliar as metodologias individuais, RRE, WD-RNA-RRE e PrevTP na Espanha (W/m <sup>2</sup> ).....	149
Tabela 6.3	Métricas para avaliar metodologias individuais, RRE, WD-RNA-RRE e PrevTP no Brasil.....	152
Tabela 6.4	Parâmetros de <i>boxplot</i> para avaliar as metodologias individuais, RRE, WD-RNA-RRE e PrevTP no Brasil (W/m <sup>2</sup> ).....	153
Tabela 6.5	Resumo de erros obtidos a partir dos sinais reconstruídos para o recurso solar nas duas localidades.....	154

Tabela 6.6	Métricas para avaliar metodologias individuais, RRE, WD-RNA-RRE e PrevTP na Espanha.....	157
Tabela 6.7	Parâmetros <i>boxplot</i> para avaliar metodologias individuais, RRE, WD-RNA-RRE e PrevTP na Espanha (m/s).....	159
Tabela 6.8	Métricas para avaliar as metodologias individuais, RRE, WD-RNA-RRE e PrevTP no Brasil.....	162
Tabela 6.9	Parâmetros de <i>boxplot</i> para avaliação de metodologias individuais, RRE, WD-RNA-RRE e PrevTP no Brasil (m/s).....	164
Tabela 6.10	Resumo de erros obtidos a partir dos sinais reconstruídos para o recurso solar nas duas localidades.....	164
Tabela 6.11	Resumo de erros obtidos por parte dos artigos considerados na qSLR e das metodologias aplicadas nesta Tese.....	166



## LISTA DE ABREVIATURAS E SIGLAS

3DVAR	<i>Three-Dimensional Variational Data Assimilation Technique</i> (Técnica de Assimilação de Dados Variacionais Tridimensionais)
4DVAR	<i>Four-Dimensional Variational Data Assimilation Technique</i> (Técnica de Assimilação de Dados Variacionais Quadridimensionais)
ABC	<i>Artificial Bee Colony</i> (Colônia de Abelhas Artificiais)
ABN	Altura da Base da Nuvem
ACE	Erro médio entre PICP e PINC
ACO	<i>Ant Colony Optimization</i> (Otimização de Colônias de Formigas)
AG	Algoritmos Genéticos
AGB	Algoritmo Genético Binário
AM	Aprendizado de Máquina
AMVO	<i>Self-Adaptive Multi-Verse Optimizer</i> (Otimizador de Multiverso Auto-adaptável)
AnEn	<i>Analog Ensemble</i> (Conjunto Analógico)
ANFIS	<i>Adaptive Neuro-Fuzzy Inference Systems</i> (Sistema de Inferência Neuro-fuzzy Adaptativo)
AR	<i>Auto Regressive</i> (Autorregressivo)
AR	Aprendizado por reforço
ARIMA	<i>Autoregressive Integrated Moving Average</i> (Média Móvel Integrada Autorregressiva)
ARMA	<i>Autoregressive Moving Average</i> (Média Móvel Autorregressiva)
ARX	<i>Autoregressive with Exogenous Inputs</i> (Autorregressivo com Entradas Exógenas)
BFGS	<i>Broyden-Fletcher-Goldfarb-Shanno</i>
BHA	<i>Bottom-up Hierarchical Approach</i> (Abordagem Hierárquica de Baixo para Cima)
BiLSTM	<i>Bidirectional Long Short-Term Memory</i> (Memória de Longo-Curto-Prazo Bidirecional)
BMA	<i>Bayesian model averaging</i> (Média do Modelo Bayesiano)
BP	<i>Back Propagation</i> (Retropropagação)
BRR	<i>Bayesian Ridge Regression</i> (Regressão de Cume Bayesiana)
BSA	<i>Bird Swarm Algorithm</i> (Algoritmo de Enxame de Pássaros)

BSRN	<i>Baseline Surface Radiation Network</i> (Rede de Radiação de Superfície de Linha de Base)
CC	Correlação Cruzada
CD	Caminhos Dinâmicos
CEEMD	<i>Complete Ensemble Empirical Mode Decomposition</i> (Decomposição de Modo Empírico de Conjunto Completo)
CFNN	<i>Cascade-Forward Artificial Neural Network</i> (Rede Neural Artificial em Cascata)
CFBP	<i>Cascade Forward Back Propagation</i> (Propagação pra Frente e Trás em Cascata)
CG	<i>Conjugate Gradient</i> (Gradiente Conjugado)
CGRU	<i>Convolutional Gated Recurrent Unit Network</i> (Rede de Unidades Recorrentes Controladas por Convolução)
CH-PeEn	<i>Complete-History Persistence Ensemble</i> (Conjunto de Persistência de Histórico Completo)
CLDDA	<i>Cloud Data Assimilation</i> (Assimilação de Dados na Nuvem)
CMV	<i>Cloud Motion Vectors</i> (Vetores de Movimento de Nuvem)
CNN	<i>Convolutional Neural Network</i> (Rede Neural Convolucional)
CQRS	<i>Constrained Quantile Regression Splines</i> (Regressão Quantílica Baseada em Funções de <i>Spline</i> Restritas)
CRS	<i>Calibrated regime-switching</i> (Mudança de Regime Calibrado)
CS	<i>Cuckoo Search</i>
CS-LS-SVM	<i>Cuckoo Search Least Squares - Support Vector Machine</i> (Busca Cuco - Mínimos Quadrados - Máquina de Vetores de Suporte)
CSO	<i>Chicken Swarm Optimization</i> (Otimização de Enxame de Galinhas)
CSO	<i>Crisscross Optimization</i> (Otimização Cruzada)
CSP	<i>Concentrating Solar Power</i> (Geração Solar Concentrada)
CST	Correlação de Séries Temporais
DA	<i>Data Assimilation</i> (Assimilação de Dados)
DBSCAN	<i>Density-Based Spatial Clustering of Applications with Noise</i> (Agrupamento Espacial Baseado em Densidade de Aplicativos com Ruído)
DEM	<i>Digital Elevation Model</i> (Modelo Digital de Elevação)

DEWA	<i>Differential Evolution - Based Weighted Average</i> (Média Ponderada Baseada na Evolução Diferencial)
DGM	<i>Discrete Gray Model</i> (Modelo Cinza Discreto)
DICast	<i>Dynamic Integrated Forecast</i> (Previsão Integrada Dinâmica)
DL	<i>Deep Learning</i> (Aprendizado Profundo)
D-PNN	<i>Differential Polynomial Neural Network</i> (Rede Neural Polinomial Diferencial)
ECC	<i>Ensemble Copula Coupling</i> (acoplamento de cópula de conjunto)
ECMWF	<i>European Center for Mid-Range Meteorological Forecasts</i> (Centro Europeu de Previsões Meteorológicas de Médio Prazo)
EEMD	<i>Ensemble Empirical Mode Decomposition</i> (Decomposição em Modo Empírico de Conjunto)
ELM	<i>Extreme Learning Machine</i> (Máquina de Aprendizagem Extrema)
EM	<i>Expectation Maximization</i> (Maximização da Expectativa)
EMD	<i>Empirical Mode Decomposition</i> (Decomposição do Modo Empírico)
EMOS	<i>Ensemble Model Output Statistics</i> (Estatísticas de saída do modelo de conjunto)
ENS	<i>Ensemble Prediction System</i> (Sistema de Previsão de Conjunto)
ESN	<i>Echo State Network</i> (Rede de Estado de Eco)
FCM	<i>Fuzzy C-Means</i> (Agrupamento Difuso)
FIGE	Fontes Intermitentes para Geração de Eletricidade
FSS	<i>Forecast Skill Score</i> (Pontuação de Habilidade de Previsão)
FV	Fotovoltaica
GAF	<i>Gramian Angular Field</i> (Campo Angular Gramiano)
GARCH	<i>Generalized Autoregressive Conditional Heteroskedastic</i> (Heteroscedástico Condicional Autorregressivo Generalizado)
GAT	<i>Graph Attention Network</i> (Grafo Rede de Atenção)
GB	<i>Gradient Boosting</i> (Aumento de Gradiente)
GCSE	<i>Geometric Cloud Shadow Edge</i> (Limite de Sombra de Nuvem Geométrica)
GGMM	<i>Generalized Gaussian Mixture Model</i> (Modelo Generalizado de Mistura Gaussiana)
GLSTM	<i>Genetic Long-Short-Term Memory</i> (Memória de Longo-Curto-Prazo Genética)
GMDH	<i>Group Method of Data Handling</i> (Método de Grupo de Tratamento de Dados)
GNN	<i>Graph Neural Network</i> (Rede Neural Grafo)

GOES	<i>Geostationary Operational Environmental Satellite</i> (Satélite Ambiental Operacional Geoestacionário)
GOP	<i>Geostatistical Output Perturbation</i> (Perturbação de Saída Geoestatística)
GP	<i>Gaussian Processes</i> (Processos Gaussianos)
GPR	<i>Gaussian Process Regression</i> (Regressão do Processo Gaussiano)
GRU	<i>Gated Recurrent Unit</i> (Unidade Recorrente Fechada)
GRUNNs	<i>Gated Recurrent Unit Neural Networks</i> (Redes Neurais de Unidades Recorrentes Fechadas)
GWO	<i>Gray wolf optimizer</i> (Otimizador de Lobo Cinzento)
HMD	<i>Hybrid Mode Decomposition</i> (Decomposição do Modo Híbrido)
HMM	<i>Hidden Markov Model</i> (Modelo Oculto de Markov)
HMMC	<i>Higher-order Multivariate Markov Chain</i> (Cadeia de Markov Multivariada de Ordem Superior)
HS	<i>Harmony Search</i> (Busca de Harmonia)
IA	Inteligência Artificial
ICEEMDAN	<i>Improved Complementary Ensemble Empirical Mode Decomposition with Adaptive Noise</i> (Decomposição de Modo Empírico de Conjunto Complementar Aprimorada com Ruído Adaptativo)
ICSO	<i>Improved Chicken Swarm Optimization</i> (Otimização Aprimorada de Enxame de Frango)
IDEWA	<i>Improved Differential Evolution - Based Weighted Average</i> (Média Ponderada Baseada na Evolução do Diferencial Aprimorada)
IGWO	<i>Improved Grey Wolf Optimization Algorithm</i> (Algoritmo de Otimização de Lobo Cinza Aprimorado)
IHD	Irradiação Horizontal Difusa
IHG	Irradiação Horizontal Global
IL	Interpolação Linear
ImDSDA	<i>Improved Dynamic Swinging Door Algorithm</i> (Algoritmo Dinâmico de Porta Oscilante)
IMODA	<i>Improved Multi-objective Dragonfly Algorithm</i> (Algoritmo de Libélula Multi-Objetivo Aprimorado)
IND	Irradiação Normal Direta
INMET	Instituto Nacional de Meteorologia

IP	Intervalo de previsão
IPMPR	<i>Interval Prediction of Electricity Demand Based on Pattern Recognition</i> (Previsão de Intervalo de Demanda de Eletricidade Baseada em Reconhecimento de Padrões)
ISO	<i>Independent System Operator</i> (Operador Independente do Sistema)
JPSN	<i>Joint Projected and Skew Normal</i>
kNN	<i>k-Nearest-Neighbors</i> (k-vizinhos mais próximos)
kNNEn	<i>k-Nearest Neighbor Ensemble</i> (Conjunto de k-vizinhos mais próximos)
KRR	<i>Kernel Ridge Regression</i> (Regressão de Cume do Kernel)
LES	<i>Linear Exponential Smoothing</i> (Suavização Exponencial Linear)
LM	<i>Levenberg-Marquardt</i>
LS-SVM	<i>Least Squares - Support Vector Machine</i> (Mínimos Quadrados - Máquina de Vetores de Suporte)
LSTM	<i>Long Short Term Memory</i> (Memória de Longo-Curto-Prazo)
LUBE	<i>Lower Upper Bound Estimation</i> (Estimativa do Limite Superior Inferior)
m2m	<i>multi-to-multi</i> (multi-para-multi)
MA	<i>Moving Average</i> (Média Móvel)
MAE	<i>Mean Absolute Error</i> (Erro Médio Absoluto)
MAPE	<i>Mean Absolute Percentage Error</i> (Erro Percentual Médio Absoluto)
MARS	<i>Multivariate Adaptive Regression Splines</i> (Splines de Regressão Adaptativa Multivariada)
MAWA	<i>Mean-value-based Weighted Average</i> (Média Ponderada Baseada no Valor Médio)
MC	<i>Matrix completion</i> (Conclusão da Matriz)
MCh	<i>Markov Chains</i> (Cadeias de Markov)
MEMD	<i>Multivariate Empirical Mode Decomposition</i> (Decomposição de Modo Empírico Multivariado)
MFOA	<i>Modified Fruit Fly Optimization</i> (Otimização da Mosca da Fruta Modificada)
MIM	<i>Mutual Information Measure</i> (Medida de Informação Mútua)
MLE	<i>Maximum Lyapunov Exponent</i> (Expoente Máximo de <i>Lyapunov</i> )
MLP	<i>Multi-Layer Perceptron</i> (Perceptron de Múltiplas Camadas)
MOALO	<i>Multi-Objective Ant Lion Algorithm</i> (Algoritmo Formiga-Leão multi-Objetivo)

MODWT	<i>Maximal Overlap Discrete Wavelet Transform</i> (Maximal Overlap Discrete Wavelet Transform)
MOMFO	<i>Multi-objective Moth-Flame Optimization</i> (Otimização de Chamas de Mariposa Multiobjetivo)
MOS	<i>Model Output Statistics</i> (Estatísticas de Saída do Modelo)
MSF	<i>Multi Step Forecasting</i> (Previsão de Várias Etapas)
MSSA	<i>Multi-objective Salp Swarm Algorithm</i> (Algoritmo de Enxame de Salpas multi-objetivo)
MTL-GP-TS	<i>Multi-Task Learning Gaussian Process Time Series</i> (Série Temporal do Processo Gaussiano de Aprendizado Multitarefa)
MTR	Mercado em Tempo Real
NAM	<i>North American Mesoscale</i> (Mesoescala Norte-Americana)
NAR	<i>Non-linear Autoregressive</i> (Autorregressivo Não Linear)
NARX	<i>Non-linear Autoregressive with Exogenous Inputs</i> (Autorregressivo Não Linear com Entradas Exógenas)
NBC	<i>Naïve Bayes Classifier</i> (Classificador <i>Naïve Bayes</i> )
nMAE	<i>Normalized Mean Absolute Error</i> (Erro Médio Absoluto normalizado)
nMBE	<i>Normalized Mean Bias Error</i> (Erro de Viés Médio Normalizado)
nRMSD	<i>Normalized Root Mean Square Difference</i> (Raiz Quadrada Média da Diferença normalizada)
nRMSE	<i>Root Normalized Mean Square Error</i> (Raiz do Erro Quadrático Médio Normalizado)
NWP	<i>Numerical Weather Prediction</i> (Previsão Numérica do Tempo)
OSORELM	<i>Online Sequential Outlier Robust Extreme Learning Machine</i> (Máquina de Aprendizagem Extrema Robusta de Discrepância Sequencial On-line)
PCA	<i>Principal Component Analysis</i> (Análise de Componente Principal)
PeEn	<i>Persistence Ensemble</i> (Conjunto de Persistência)
PEM	<i>Prediction Error Minimization</i> (Minimização de Erros de Previsão)
PICP	<i>Prediction Interval Coverage Probability</i> (Probabilidade de Cobertura do Intervalo de Previsão)
PMA	<i>Pattern-Matching Algorithm</i> (Algoritmo de Correspondência de Padrões)
PQ	Programação Quadrática
PrevTP	Previsão baseada na Teoria do Portfólio

PSO	<i>Particle Swarm Optimization</i> (Otimização de Enxame de Partículas)
PSO-WA	<i>Particle Swarm Optimization - Weighted Average</i> (Otimização de Enxame de Partículas – Média ponderada)
PSS	<i>Predictor Subset Selection</i> (Seleção de Subconjunto Preditor)
TP	Teoria do Portfólio
p-WPRF	<i>Probabilistic Wind Power Ramp Forecasting</i> (Previsão Probabilística de Rampa de Energia Eólica)
R	Coefficiente de Correlação de <i>Pearson</i>
RBF	<i>Radial Basis Function</i> (Função de Base Radial)
RD	Resposta à demanda
RDFM	<i>Reliable Deep Forecasting Model</i> (Modelo Confiável de Previsão Profunda)
RELM	<i>Robust Extreme Learning Machine</i> (Máquina de Aprendizagem Extrema Robusta)
RF	<i>Random Forest</i> (Floresta Aleatória)
RHC	<i>Receding Horizon Optimization Algorithm</i> (Algoritmo de Otimização do Horizonte Recuando)
RLM	Regressão Linear Multipla
rMBE	<i>Relative Mean Bias Error</i> (Erro de Viés Médio relativo)
RMSE	<i>Root Mean Square Error</i> (Raiz do Erro Quadrático Médio)
RNA	Redes Neurais Artificiais
RNN	<i>Recurrent Neural Network</i> (Rede Neural Recorrente)
RP	<i>Resilient Backpropagation</i> (Retropropagação Resiliente)
RR	<i>Ridge Regression</i> (Regressão de Cume)
RRE	<i>Ridge Regression Ensemble</i> (Conjunto de Regressão de Cume)
RREd	<i>Ridge Regression Dynamic Ensemble</i> (Conjunto Dinâmico de Regressão de Cume)
rRMSE	<i>Relative Root Mean Square Error</i> (Erro Quadrático Médio relativo)
RVFL	<i>Random Vector Functional Link</i> (Link Funcional de Vetor Aleatório)
SAF CM	<i>Satellite Application Facility on Climate Monitoring</i> (Facilidade de Aplicação de Satélite em Monitoramento do Clima)
SAM	<i>System Advisor Model</i> (Modelo de Consultor do Sistema)
SARIMA	<i>Seasonal Autoregressive Integrated Moving Average</i> (Média Móvel Integrada Autorregressiva Sazonal)

Sc	Nuvens Costeiras do tipo <i>Stratocumulus</i>
SD	<i>secondary decomposition</i> (Decomposição Secundária)
SDAE	<i>Stacked Denoising Auto-Encoder</i> (Codificador Automático de Redução de Ruído Empilhado)
SES	<i>Single Exponential Smoothing</i> (Suavização Exponencial Simples)
sHDP-HMM	<i>Sticky Hierarchical Dirichlet Process HMM</i> (Processo de Dirichlet Hierárquico pegajoso - HMM)
SOM-BP	<i>Self-Organizing Map Back Propagation</i> (Propagação Retroativa do Mapa Auto-Organizado)
SSAWD- MOGAPSO- CM	<i>Secondary De-Noising - Modified Multi-Objective - Combined Forecasting Method</i> (Eliminar Ruído Secundário - Multiobjetivo Modificado - Método de Previsão Combinada)
SVD	<i>Singular Value Decomposition</i> (Decomposição de Valor Singular)
SVM	<i>Support Vector Machine</i> (Máquina de Vetores de Suporte)
SVR	<i>Support Vector Regression</i> (Regressão de Vetor de Suporte)
TDF	Transformada Discreta de Fourier
TECI	<i>Typical Event Clustering Identification</i> (Identificação Típica de Agrupamento de Eventos)
UB	<i>Uncertain Basic Functions</i> (Funções Básicas Incertas)
VB- ConvGRU	<i>Variational Bayesian Convolutional Gated Recurrent Unit</i> (Unidade Recorrente Fechada Convolutacional Bayesiano Variacional)
VE	Veículos Elétricos
VMD	<i>Variational Mode Decomposition</i> (Decomposição de Modo Variacional)
VOF	<i>Variational Optical Flow</i> (Fluxo Óptico Variacional)
WD	<i>Wavelet Decomposition</i> (Decomposição <i>Wavelet</i> )
WEMPP	<i>Well-Mixed Preprocessor</i> (Pré-processador Bem Misturado)
WGPR	<i>Weighted Gaussian Process Regression</i> (Regressão do Processo Gaussiano Ponderado)
WNN	<i>Wavelet Neural Networks</i> (Redes Neurais <i>Wavelet</i> )
WOA	<i>Whale Optimization Algorithm</i> (Algoritmo de Otimização de Baleias)
WPRs	<i>Wind Power Ramps</i> (Rampas de Energia Eólica)
WRF	<i>Weather Research and Forecasting</i> (Pesquisa e Previsão do Tempo)



WRFDA	<i>Weather Research and Forecasting Data Assimilation</i> (Pesquisa Meteorológica e Assimilação de Dados de Previsão)
WSTD	<i>Wavelet Soft Threshold Denoising</i> (Eliminação de Ruído de Limiar Suave de Wavelet)
WT	<i>Wavelet Transform</i> (Transformada Wavelet)
XGBoost	<i>Extreme Gradient Boosting</i> (Aumento de Gradiente Extremo)

## LISTA DE SÍMBOLOS

%	Porcentagem
m <sup>2</sup>	Metro Quadrado
W	Watts
W/m <sup>2</sup>	Watts por metro quadrado
Wh/m <sup>2</sup>	Watt-hora por metro quadrado
min	Minuto
h	Hora
s	Segundo
kW	Quilowatt
kWp	Quilowatt-pico
MJ/m <sup>2</sup>	Mega Joule por metro quadrado
MW	Megawatt
m/s	Metros por segundo
GW	Gigawatt
GWh	Gigawatt-hora
kWh/kWp.mês	Quilowatt-hora por Quilowatt-pico mês
TWh	Terawatt-hora

## SUMÁRIO

1	<b>INTRODUÇÃO.....</b>	30
1.1	<b>Motivação.....</b>	31
1.2	<b>Objetivos, Contribuições e Estrutura.....</b>	34
2	<b>FONTES INTERMITENTES PARA GERAÇÃO DE ELETRICIDADE.....</b>	36
2.1	<b>Matriz Elétrica Brasileira.....</b>	37
2.2	<b>Matriz Elétrica da Espanha.....</b>	40
3	<b>STATUS E TENDÊNCIAS DA PREVISÃO EÓLICA E SOLAR..</b>	43
3.1	<b>Revisão Sistemática: Protocolo.....</b>	45
3.2	<b>Metodologias de Previsão Solar.....</b>	47
3.2.1	<i>Estado da Arte.....</i>	50
3.2.1.1	<i>Previsão do Recurso Solar Baseada em Aprendizado de Máquina.....</i>	50
3.2.1.2	<i>Previsão da Geração FV Baseada em Aprendizado de Máquina.....</i>	54
3.2.1.3	<i>Modelos Fenomenológicos (Previsão Numérica do Tempo) para a Previsão do Recurso Solar.....</i>	55
3.2.1.4	<i>Modelos Fenomenológicos (Previsão Numérica do Tempo) para a Previsão da Geração FV.....</i>	58
3.2.1.5	<i>Previsão do Recurso Solar Baseada em Modelos Estatísticos.....</i>	58
3.2.1.6	<i>Previsão da Geração FV Baseada em Modelos Estatísticos.....</i>	60
3.2.1.7	<i>Modelos Híbridos para a Previsão do Recurso Solar.....</i>	61
3.2.1.8	<i>Modelos Híbridos para a Previsão da Geração FV.....</i>	67
3.2.2	<b>Classificação dos artigos de revisão analisados e cronologia das Técnicas Aplicadas.....</b>	70
3.2.3	<b>Métricas de Avaliação de Desempenho.....</b>	74
3.2.4	<b>Discussão: Análise Global.....</b>	75
3.2.5	<b>Discussão: Análise por Técnica.....</b>	77
3.3	<b>Metodologias de Previsão Eólica.....</b>	80
3.3.1	<i>Estado da Arte.....</i>	84
3.3.1.1	<i>Previsão do Recurso Eólico Baseada em Aprendizado de Máquina.....</i>	84

3.3.1.2	<i>Previsão da Geração Eólicoelétrica Baseada em Aprendizado de Máquina.....</i>	85
3.3.1.3	<i>Modelos Fenomenológicos (Previsão Numérica do Tempo) para a Previsão do Recurso Eólico.....</i>	85
3.3.1.4	<i>Previsão do Recurso Eólico Baseada em Modelos Estatísticos.....</i>	86
3.3.1.5	<i>Previsão da Geração Eólicoelétrica Baseada em Modelos Estatísticos.....</i>	87
3.3.1.6	<i>Modelos Híbridos para a Previsão do Recurso Eólico.....</i>	88
3.3.1.7	<i>Modelos Híbridos para a Previsão da Geração Eólicoelétrica.....</i>	92
3.3.2	<b>Classificação dos artigos analisados.....</b>	95
3.3.3	<b>Métricas de Avaliação de Desempenho.....</b>	98
3.3.4	<b>Discussão: Análise Global.....</b>	99
3.3.5	<b>Discussão: Análise por Técnica.....</b>	101
3.4	<b>Considerações Preliminares.....</b>	103
4	<b>PREVISÕES DE CONJUNTO (ENSEMBLE).....</b>	105
5	<b>METODOLOGIA.....</b>	111
5.1	<b>Obtenção de Dados.....</b>	111
5.2	<b>Técnicas Individuais.....</b>	112
5.2.1	<i>Multilayer Perceptron (MLP).....</i>	114
5.2.2	<i>Radial Basis Function (RBF).....</i>	116
5.2.3	<i>Cascade Forward Back Propagation (CFBP).....</i>	119
5.2.4	<i>Self-Organizing Map (SOM) .....</i>	120
5.3	<b>Metodologias Ensemble Utilizadas para Integração das Previsões Individuais.....</b>	123
5.3.1	<i>PrevTP.....</i>	123
5.3.2	<i>Ridge Regression Ensemble (RRE).....</i>	133
5.3.3	<i>Modelo híbrido que combina Decomposição Wavelet, Aprendizado de Máquina e Ridge Regression Ensemble.....</i>	130
5.4	<b>Análise dos Resultados.....</b>	141
6	<b>RESULTADOS E DISCUSSÕES.....</b>	143
6.1	<b>Previsões de Recurso Solar para Brasil e Espanha usando Técnicas Individuais, RRE, WD-RNA-RRE e PrevTP.....</b>	143
6.1.1	<b>Resultados – Espanha.....</b>	143

6.1.2	<i>Resultados – Brasil</i> .....	149
6.2	<b>Previsões de Recurso Eólico para Brasil e Espanha usando Técnicas Individuais, RRE, WD-RNA-RRE e PrevTP</b> .....	154
6.2.1	<i>Resultados – Espanha</i> .....	154
6.2.2	<i>Resultados – Brasil</i> .....	159
7	<b>CONCLUSÃO</b> .....	168
	<b>SUGESTÕES PARA TRABALHOS FUTUROS</b> .....	171
	<b>ARTIGOS PUBLICADOS VINCULADOS AO PROJETO DE TESE</b> .....	172
	<b>REFERÊNCIAS</b> .....	174
	<b>ANEXO A –VALIDAÇÃO CRUZADA PARA OS MÉTODOS INDIVIDUAIS BASEADOS EM APRENDIZADO DE MÁQUINA</b> .....	204
	<b>ANEXO B – DETALHAMENTO DAS DIFERENTES SÉRIES DECOMPOSTAS POR MEIO DA DW</b> .....	214

## 1 INTRODUÇÃO

Os países estão buscando utilizar energias renováveis para reduzir as emissões de gases poluentes e melhorar suas matrizes de geração de eletricidade, sendo as energias eólica e solar uma parte relevante desse processo (Heydari *et al.*, 2019, Liu *et al.*, 2020a). As energias renováveis têm se apresentado como uma alternativa relevante para substituir o uso de combustíveis fósseis que, além de contaminar o meio ambiente, possuem prazo de validade por ser um recurso não renovável.

As fontes renováveis já são responsáveis por 60% da matriz de energia elétrica espanhola, com predominância das gerações eólica, solar e hídrica (Reddata da Red Electrica de Espanã, 2023), nessa ordem. O País vem promovendo a difusão das fontes renováveis, visando reduzir a emissão de gases de efeito estufa na atmosfera. Com relação à matriz elétrica brasileira, ela é predominantemente composta por fontes renováveis de energia, especialmente as hidrelétricas, complementada pelas termelétricas em períodos em que os reservatórios hídricos estejam com baixos níveis. O incremento no uso da geração eólica e solar, observado nos últimos anos (ABSOLAR, 2023), complementa a geração hídrica e diversifica a matriz, gerando maior confiabilidade ao sistema elétrico.

A geração de eletricidade por meio de fontes solar e eólica tem atraído considerável atenção de pesquisadores, devido à abundância dos recursos em diferentes regiões do mundo e à sustentabilidade associada (Zendehboudi; Baseer; Saidur, 2018). Apesar dos benefícios dessas fontes mencionadas, surgem problemas ao utilizá-las no setor elétrico: variação da intensidade e direção do vento, alternância de períodos nublados e ensolarados, desafios diretamente associados à intermitência dos recursos (Antonanzas *et al.*, 2016; Liu e Sun, 2019; Liu *et al.*, 2017).

Assim, o conhecimento do comportamento das séries dos recursos solar e eólico e a modelagem de sistemas de previsão eficientes podem ser ferramentas importantes para um uso ainda maior e mais seguro dessas duas fontes (Kabouris; Kanellos, 2010; Wang *et al.*, 2019c; Pedro; Coimbra, 2015a; Liu *et al.*, 2019a). Tais ferramentas podem fornecer informações para auxiliar na implantação de parques eólicos e solares e durante sua operação, atuando em mercados de desequilíbrio de energia, trazer redução nos recursos de *backup*.

Técnicas avançadas de previsão eólica e solar têm potencial para melhorar o uso desses recursos intermitentes, contribuindo para a integração das usinas e o equilíbrio entre oferta e demanda (Kaur *et al.*, 2016). Existem desafios para tornar as fontes renováveis mais confiáveis,

como as metodologias de previsão que visam melhorar o entendimento da natureza não programada associada aos recursos solar e eólico (Nespoli *et al.*, 2022).

## 1.1 Motivação

Existem vários métodos para auxiliar na tarefa de previsão de séries temporais, como modelos derivados de física, aprendizado de máquina (AM) (Mert Yagli; Yang; Srinivasan, 2019; Brito *et al.*, 2006) e modelos estatísticos (Alencar; Stedile; Junior, 2018). Modelos de previsão são comumente usados para prever o comportamento de séries de velocidade do vento, demanda de eletricidade, irradiação solar e precipitação (Sideratos; Hatzigiorgiou, 2007; Hong; Wu, 2007).

Nos últimos anos, diferentes metodologias foram implementadas para melhorar a precisão de modelos individuais, usando ajuste de erros para melhorar as previsões e combinando modelos para gerar melhores resultados. Em vários países, são exigidas penalidades econômicas dos produtores de energia elétrica, e estas são proporcionais aos erros nas previsões de energia para o dia seguinte, tornando a precisão das previsões um fator determinante na redução das perdas econômicas (Alessandrini *et al.*, 2015). Artigos científicos na área de previsão apresentam a combinação de modelos como preferível às metodologias aplicadas individualmente (Atiya, 2020; Taylor, 2020).

Uma abordagem corretiva pode ser encontrada em Wang *et al.* (2019c), a programação quadrática (PQ) é utilizada com o objetivo de corrigir erros e reduzir os impactos da variabilidade solar em edifícios na Califórnia, EUA. Um sistema de previsão híbrido combinando a Teoria do Portfólio (TP) e diferentes técnicas de inteligência computacional foi ilustrado em Lima *et al.* (2020), onde os resultados das previsões individualizadas foram aprimorados usando erros de previsão e a integração de diferentes técnicas. Uma abordagem de ajuste para melhorar a previsão agrupada e prever eventos de rampa solar com mais precisão foi encontrada em Abuella e Chowdhury (2019).

Uma abordagem heurística para melhorar e corrigir erros de previsão de carga isolada em sistemas de potência por meio da teoria de estabilidade de rastreamento de trajetória foi proposta em (Song *et al.*, 2014). Um modelo autorregressivo ajustado a dados para capturar o comportamento estocástico dos erros de previsão do dia seguinte e produzir previsões de séries temporais autocorrelacionadas foi usado em (Haessig *et al.*, 2015).

Uma simulação comparando erros de previsão solar do dia seguinte em regiões com diferentes tamanhos geográficos foi ilustrada em Nuño *et al.* (2017). Um modelo *Autoregressive Moving Average* (ARMA) foi usado em Nuño *et al.* (2018) para modelar erros de previsão de média horária para o dia seguinte. *Bayesian Model Averaging* (BMA) foi implementado em Doubleday *et al.* (2021) para prever a geração fotovoltaica (FV) em diferentes horizontes. O pós-processamento por meio de BMA foi realizado para conjuntos de *Numerical Weather Prediction* (NWP).

Considerando o contexto acima, diferentes metodologias foram encontradas na literatura, algumas utilizaram erros de previsão para melhorar os resultados, alguns modelos *ensemble* misturaram modelos padrões para alcançar um produto de maior desempenho (Zhang; Ma, 2012), alguns métodos *ensemble* são aplicados diretamente (Tazim *et al.*, 2020; Sunil *et al.*, 2021), e outros combinaram os resultados obtidos separadamente por diferentes modelos (Soumyashree *et al.*, 2021).

Em Cervone *et al.* (2017), uma metodologia baseada em Redes Neurais Artificiais (RNA) e um *Analog Ensemble* (AnEn) é usada para gerar 72 h de previsão da geração FV determinística e probabilística usando modelo numérico de previsão do tempo e variáveis astronômicas computadas como dados de entrada. Um modelo híbrido, uma combinação de *Secondary De-Noising - Modified Multi-Objective - Combined Forecasting Method* (SSAWD-MOGAPSO-CM), para previsão de velocidade do vento de curto prazo é encontrado em Zhou, Wang e Zhang (2020). Em Altan, Karasu e Zio (2021) um modelo híbrido combina os métodos LSTM, *improved complementary ensemble empirical mode decomposition with adaptive noise* (ICEEMDAN) e *gray wolf optimizer* (GWO) para previsão da velocidade do vento. A irradiação solar é estimada em Karasu e Altan (2019) usando o modelo de *Random Forest* (RF) com uma abordagem de seleção de preditores.

Técnicas de redução multivariada e modelos de cadeia de *Markov* para combinar previsões da geração eólica foram aplicadas em Poncela-Blanco e Poncela (2021). A irradiação solar foi estimada por regressão linear e métodos de regressão de processo gaussiano usando dados de 1 ano de séries temporais diárias de uma província na Turquia em Karasu *et al.* (2017). Um *self-adaptive multi-verse optimizer* (AMVO) é aplicado em Wang *et al.* (2018) para otimizar os parâmetros da *Support Vector Machine* (SVM), empregando um esquema de validação cruzada contínua para prever o consumo de energia primária da China. Em Ahmad, Mourshed e Rezgui (2017) é avaliado o desempenho de uma RNA *feed-forward* e seu



desempenho é comparado com o método RF *ensemble* para prever o consumo horário de energia em um ambiente construído em Madri, Espanha.

Uma nova metodologia *Interval prediction of electricity demand based on pattern recognition* (IPMPR) é proposta em Serrano-Guerrero *et al.* (2021), que limita a incerteza de previsão por meio de análise estatística robusta considerando a sazonalidade dos dados com baixa complexidade computacional.

Na Tabela 1.1 é apresentado um resumo de artigos analisados na revisão de literatura.

Tabela 1.1 - Resumo de alguns artigos da revisão de literatura

<b>Autores</b>	<b>Modelo/ Abordagem</b>	<b>Horizonte de Previsão</b>	<b>Meta de Previsão</b>	<b>Desvantagens</b>	<b>Vantagens</b>
(Cervone <i>et al.</i> , 2017)	RNA e AnEn / Híbrido	72 horas	Geração FV	Necessidade de grande volume de dados (astronômicos, meteorológicos e sintéticos); Alto custo computacional.	Adequado para computação paralela; a escalabilidade é testada.
(Lima <i>et al.</i> , 2020)	RNA (MLP, RBF, SVR e DL) e TP / Híbrido	diferentes horizontes	Irradiação solar e temperatura	Possibilidade de exclusão de preditores em função da arquitetura otimizada e definição de pesos; Alto custo computacional.	Comparação entre modelos consolidados.
(Zhou; Wang; Zhang, 2020)	SSAWD-MOGAPSO-CM / Híbrido	diário	Velocidade do vento	Aplicação específica e alto custo computacional.	Escolha ideal de submodelos a serem combinados; elimina o ruído.
(Altan; Karasu; Zio, 2021)	LSTM, ICEEMDAN e GWO / Híbrido	10 horas	Velocidade do vento	Alto custo computacional.	Inclusão de preenchimento e pré-processamento de dados; aplicado a diferentes regiões.
(Karasu; Altan, 2019)	RF / AM	horário	Irradiação solar	Não uso de métodos para comparação.	Bons resultados e uso de parâmetros meteorológicos.
(Poncela-Blanco; Poncela, 2021)	Cadeia de <i>Markov</i> e técnica para redução dimensional / Híbrido	horário	Geração eólica	-	Estimativa de pesos de forma adaptativa.
(Karasu <i>et al.</i> , 2017)	Regressão linear e regressão de	diário	Irradiação solar	-	Validação cruzada aplicada

	processo gaussiano / Híbrido				10 vezes.
(Wang <i>et al.</i> , 2018)	AMVO-SVM / Híbrido	anual	Consumo de energia	Necessidade de previsão prévia de PIB per capita, população, taxa de urbanização, estrutura econômica e estrutura energética.	Maior precisão e exatidão; Melhor capacidade de exploração e otimização de parâmetros; Resultados próximos aos resultados obtidos pelas instituições locais.
(Ahmad; Mourshed; Rezgui, 2017)	RNA (MLP) vs RF / AM	horário	Consumo de energia	Aplicação específica.	Incorporação de modelo em um módulo de software; Uso de RF como seletor de variáveis.
(Serrano-Guerrero <i>et al.</i> , 2021)	Reconhecimento de padrões e estatísticas inferenciais / Híbrido	15 minutos	Cargas elétricas	Alto custo computacional; Dificuldade em quantificar a incerteza dos resultados e interpretá-los fisicamente.	Límite da incerteza das previsões; uso para qualquer tipo de consumidor; Detecção de anomalias e ineficiências no consumo de energia elétrica.

Fonte: Próprio autor.

## 1.2 Objetivos, Contribuições e Estrutura

A presente Tese tem como objetivo geral a aplicabilidade de dois modelos “*ensemble*” que serão utilizados para integrar e combinar quatro tipos diferentes de RNA utilizadas para melhorar a previsibilidade dos recursos solar e eólico em locais específicos do Brasil e da Espanha. As metodologias de combinação (*ensemble*) são: a) Modelo *Ridge Regression Ensemble* (RRE); e b) um modelo híbrido que utiliza *WD – RNA – RRE*. Para comparação dos resultados obtidos pelos modelos propostos é aplicada a metodologia de integração de previsões baseada na Teoria do Portfólio (PrevTP) (Lima, 2020).

Os objetivos específicos são:

- Coleta e tratamento de dados;
- Implementação das técnicas individuais bem como suas combinações (CFBP, MLP, RBF e SOM);
- Comparação dos resultados obtidos com os resultados do PrevTP (Lima, 2020); e

- Apresentação dos resultados obtidos pelas técnicas individuais e pelos dois modelos “*ensemble*”.

As principais contribuições das aplicações desta Tese incluem:

- Aplicação para diferentes fontes intermitentes (solar e eólica) de geração de energia elétrica;
- Aplicação em dois locais com latitudes diferentes e conseqüentemente perfis climáticos distintos, podendo ser aplicadas a outras localidades;
- Não necessidade de remoção de um preditor *a priori*, permitindo todas as contribuições possíveis;
- Simplicidade e baixo custo computacional;
- Não existência de abordagem semelhante na literatura, especialmente para o caso específico de fontes renováveis solar e eólica; e
- Melhoria no desempenho dos preditores individuais e posteriormente no desempenho do RRE devido à redução de oscilações, picos e diferentes tipos de componentes de dados não estacionários inerentes aos dados eólico e solar.

A Tese está estruturada da seguinte forma: no Capítulo 2, é apresentada uma contextualização sobre fontes intermitentes para geração de eletricidade; no Capítulo 3 são apresentadas duas revisões sistemáticas em relação aos temas previsão solar e previsão eólica; no Capítulo 4 é escrita a contextualização dos modelos de previsão de conjunto (*ensemble*); a metodologia desenvolvida apresentada no Capítulo 5; os resultados e discussões são apresentados no Capítulo 6; por fim, as conclusões são detalhadas no Capítulo 7. As referências são apresentadas na sequência.

## 2 FONTES INTERMITENTES PARA GERAÇÃO DE ELETRICIDADE

Fontes intermitentes para geração de eletricidade (FIGE), incluindo as fontes eólica e solar, têm sido rapidamente integradas aos sistemas de energia devido a diversas razões econômicas e ambientais (Wei *et al.*, 2017; Liu *et al.*, 2017; Alencar; Stedile; Junior, 2018).

O setor produtivo que envolve a geração de energia elétrica, de acordo com Bueno e Brandão (2016), tem passado por transformações que incluem: a) surgimento de geração distribuída e a mudança do perfil de grandes produções elétricas em usinas centralizadas; e b) Redes Inteligentes (*Smartgrids*) para o controle dos fluxos de energia, em que o perfil de geração unidirecional (da usina produtora até os centros de cargas) praticado por muitos anos passa a ser multidirecional, em que os centros consumidores também podem injetar energia elétrica no sistema e contribuir para o total gerado.

Essas mudanças observadas nos setores elétricos dos países demonstram o incremento dos últimos anos no uso de FIGE, distribuídas ou centralizadas, conectadas à rede ou isoladas. Essas FIGE apresentam como principais características serem imprevisíveis e não despacháveis, dependentes muitas vezes de condições climáticas e do tempo para definição do que poderá ser gerado por cada uma delas (Cavados, 2015). Os principais recursos naturais utilizados por FIGE são: recurso hídrico (usinas hidrelétricas), recurso solar (diretamente nos parques fotovoltaicos (FV) e indiretamente nos parques eólicos) e recurso eólico (parques eólicos).

As políticas adotadas para o despacho de FIGE devem considerar a disponibilidade dos recursos intermitentes e considerar aqueles, como o recurso hídrico, que podem ser armazenados para geração futura (Wang; Guo, 2018). Chamado por Bueno e Brandão (2016) de modulação inversa, são acomodadas as flutuações dos diferentes recursos permitindo a geração máxima dos parques eólicos e FV e o uso para compensação das fontes que permitam o armazenamento do recurso (como a geração hidrelétrica).

A geração eólica somente está disponível quando o vento sopra a partir de determinados níveis de velocidade. A geração solar varia com o nível de irradiação incidente na superfície dos módulos FV, sendo variável a cada dia, mês e ano levando em consideração o movimento do planeta, podendo variar também com a nebulosidade local. Assim, à medida que a participação das fontes eólica e solar cresce nas matrizes elétricas dos países, maior é a estocasticidade e intermitência na geração de energia elétrica e diversos impactos podem ser gerados, a depender de cada localidade e da capacidade de cada matriz elétrica em absorver essas flutuações.

Essa incerteza na geração, essa possibilidade de comprometimento do balanceamento de energia em tempo real, bem como da segurança e estabilidade do sistema de energia deve ser contornada visando melhorar constantemente a inserção de FIGE aos sistemas de energia. Contornar os problemas de incerteza e imprevisibilidade inerentes às FIGE incluem três principais aspectos:

- uso e produção de sistemas preditivos eficientes que venham a mitigar os efeitos das flutuações dos recursos intermitentes (Sperati *et al.*, 2015; Pedro; Coimbra, 2015; Yan *et al.*, 2016; Kaur *et al.*, 2016; Wang *et al.*, 2019; Lima *et al.*, 2020; Carneiro *et al.*, 2021);
- aumento da capacidade de geração em rampa por meio da inserção de eficientes sistemas de armazenamento de energia (Liu; Guan, 2016; Liu *et al.*, 2017); e
- utilização de fontes despacháveis (com baixos tempos de notificação), ou seja, que podem ser ligadas rapidamente mediante necessidade (Pinheiro, 2020).

Considerando a importância dos modelos preditivos e a necessidade de entendimento da formação das matrizes elétricas para a compreensão de como deve ser trabalhada a questão da inserção das FIGE nos países, nas seções 2.1 e 2.2 são apresentadas as matrizes elétricas do Brasil e da Espanha, respectivamente. Dados dos recursos solar e eólico dos dois países são utilizados como entrada para previsões nas aplicações da presente Tese.


## 2.1 Matriz Elétrica Brasileira

Na matriz elétrica brasileira, aproximadamente 79% da eletricidade é produzida por meio de fontes renováveis, como é apresentado na Figura 2.1. Embora composta principalmente por hidrelétricas (57,5%), a matriz elétrica nacional é relativamente diversificada; mesmo assim, apresenta limitações como: a) construção de grandes reservatórios; b) Modificação do meio ambiente por conta de inundação e da instalação de linhas de transmissão; c) distância das regiões com maior potencial hídrico dos grandes centros de consumo; d) custo ambiental cada vez maior (ABEEólica, 2022); e e) limitação na produção nos períodos de estiagem.

A concentração de mais de 50% da matriz elétrica em hidrelétricas pode resultar em uma menor oferta de eletricidade em períodos de escassez de chuvas, reduzindo a confiabilidade da matriz para atendimento às demandas. Diversas regiões do Brasil apresentam uma

sazonalidade bem definida, com fortes chuvas no primeiro semestre e períodos mais secos no segundo semestre.

Figura 2.1 - Matriz Elétrica Brasileira 2023



Fonte: INFOGRÁFICO da ABSOLAR (2023).

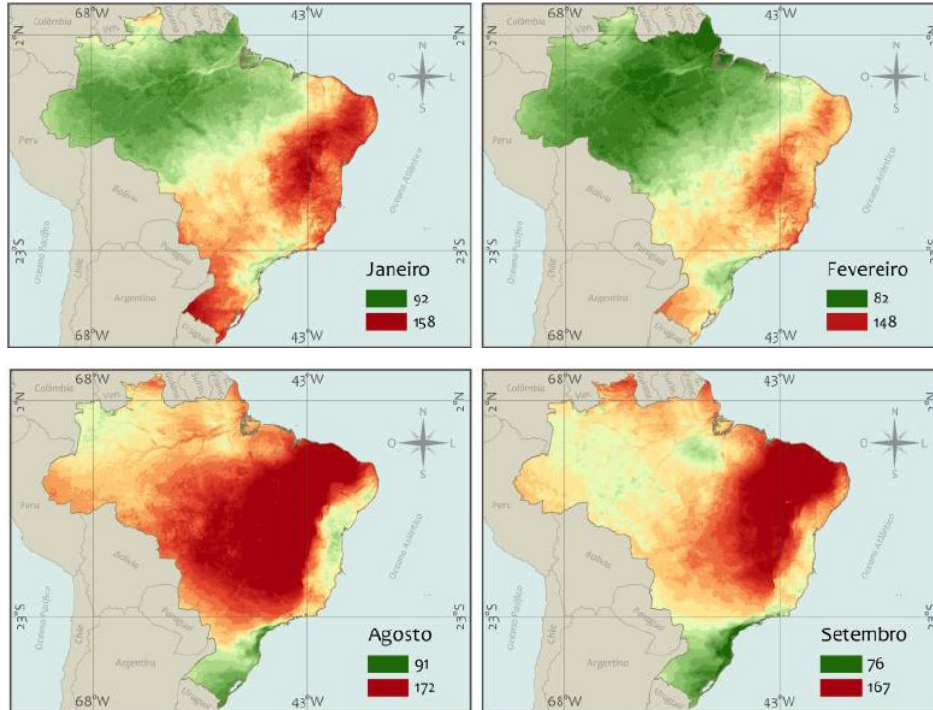
As fontes eólica e solar são bastante viáveis pois, além de serem renováveis, têm o seu maior potencial nos períodos em que há baixa pluviosidade, podendo assim suprir os déficits das hidrelétricas. De acordo com a Associação Brasileira de Energia Eólica - ABEEólica (2023) o Brasil apresenta, em julho de 2023, um total de 916 usinas eólicas instaladas, com 26 GW de capacidade instalada. A partir do INFOGRÁFICO da Associação Brasileira de Energia Solar Fotovoltaica - ABSOLAR (2023) a geração solar, até julho de 2023, apresenta capacidade instalada em torno de 32 GW, incluindo a geração distribuída e centralizada.

O potencial de geração FV no Brasil varia durante todo o ano, a depender das condições climáticas, sendo o primeiro semestre caracterizado pelo menor potencial de geração devido aos altos índices pluviométricos e o segundo semestre do ano pelo maior potencial devido aos baixos índices pluviométricos (Pereira *et al.*, 2017). A Figura 2.2 apresenta janeiro e fevereiro como o período de menor produtividade FV e agosto e setembro como os meses de maior produtividade FV.

Na Figura 2.3 são apresentados os valores de velocidade do vento para uma altura de 150 metros; as maiores velocidades do vento são apresentadas nas regiões litorâneas e as

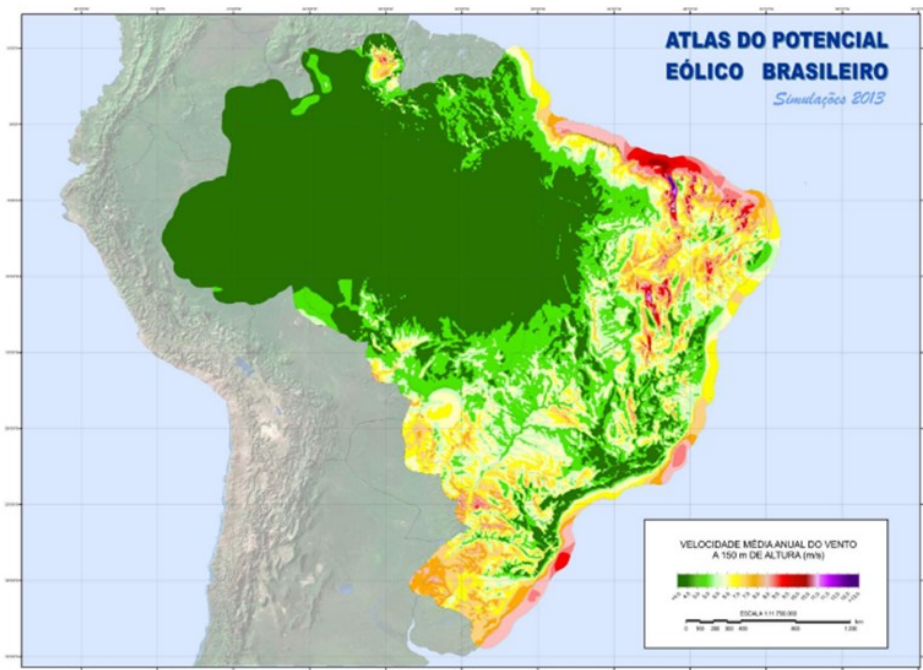
menores velocidades do vento estão presentes na região Norte. O potencial eólico brasileiro é estimado em 143,5 GW (Amarante, 2001).

Figura 2.2 – Produtividade FV (kWh/kWp)



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

Figura 2.3 – Mapa temático de velocidade média anual para a altura de 150 metros




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

## 2.2 Matriz Elétrica da Espanha

A geração e, especialmente, o consumo de eletricidade representam um desafio para a economia espanhola. Devido à dependência do exterior para importação de recursos naturais, há flutuações frequentes de preço, resultando em problemas econômicos (Facto Energy/Giz, 2018). Considerando essa realidade e de acordo com Sallé Alonso (2012), a Espanha há anos tem sido um dos países da União Europeia que tem buscado promover a difusão das fontes renováveis, visando reduzir a emissão de gases de efeito estufa na atmosfera.

Em 2023, a Espanha atingiu cerca de 60% da capacidade instalada com fontes renováveis. Importante o destaque para a fonte eólica, que representou aproximadamente 42% do total de eletricidade renovável produzida. A matriz elétrica de 2023 é apresentada na Figura 2.4, onde observa-se uma participação da fonte eólica com 30% e FV com 18% (*Red Electrica de Espanã, 2023*); em 2016 a eólica representava 18,4% e a FV 3,1% (Facto Energy/Giz, 2018).



Fonte: Adaptado de Reddata da *Red Electrica de Espanã* (2023).

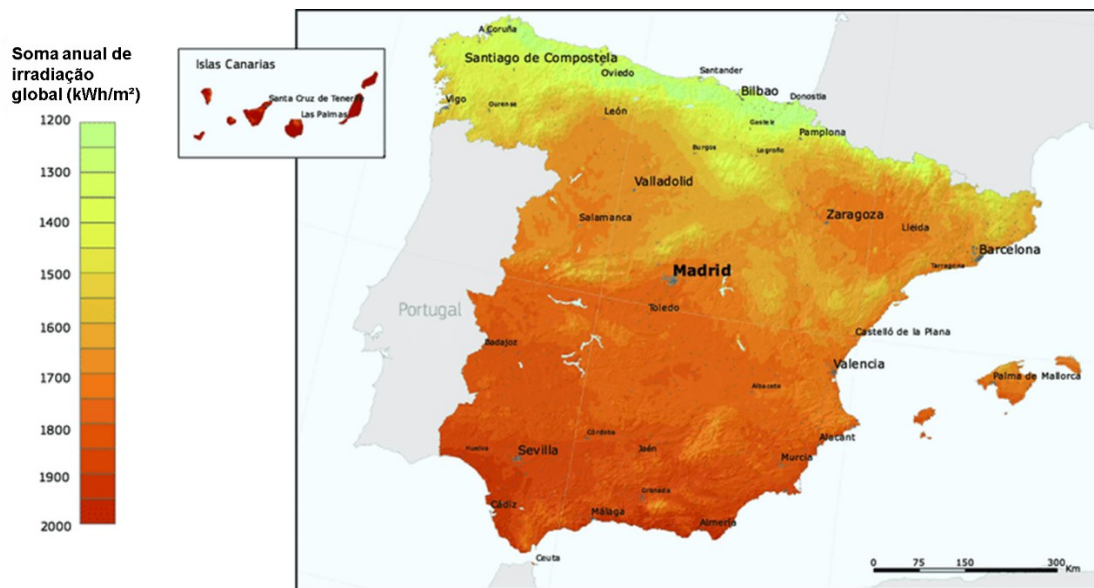
Considerando as metas para o incremento de energias renováveis na matriz elétrica da Espanha, é possível perceber que o País vem conseguindo obter resultados que demonstram o maior uso de fontes renováveis e da redução do uso de recursos que necessitam de importação. Os estudos voltados à caracterização e à previsão de recursos eólico e solar no País podem vir



a reduzir os impactos negativos inerentes aos recursos e vir a contribuir nas tomadas de decisões em parques eólicos e FV, trazendo benefícios.

Os recursos solar e eólico na Espanha são apresentados nas Figuras 2.5 e 2.6 por meio da apresentação da irradiação horizontal global anual e dos índices de velocidade do vento, respectivamente. Ambas as fontes apresentam considerável disponibilidade e estão com nível importante de crescimento no cenário nacional.

Figura 2.5 – Irradiação horizontal global na Espanha

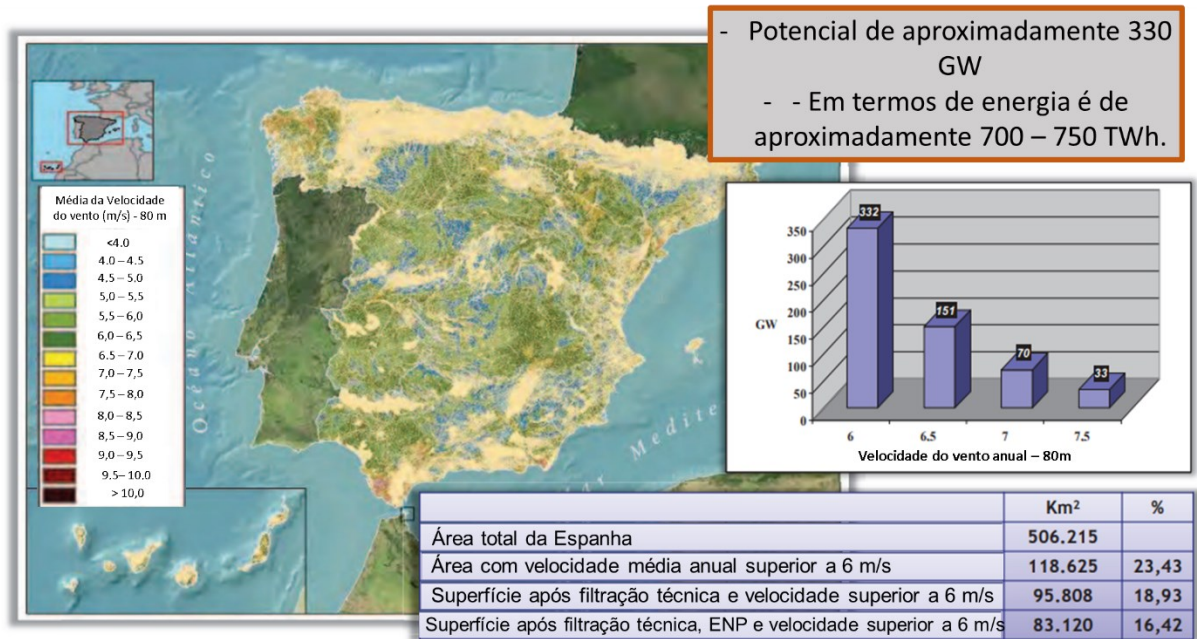


Fonte: Adaptado de PVGIS© European Union.

Segundo Ortiz (2011) o potencial eólico da Espanha é de 330 GW, com aproximadamente 23% da área territorial com velocidades do vento acima de 6 m/s, podendo gerar aproximadamente 750 TWh de energia elétrica.

O Brasil e a Espanha apresentam matrizes elétricas e potenciais geradores para a produção de eletricidade com altos níveis de contribuição das energias renováveis. As suas matrizes elétricas vêm passando por modificações ao longo dos anos e sendo diversificadas de modo a aumentar ainda mais a contribuição das FIGE.

Figura 2.6 – Velocidade do vento, em m/s, na Espanha



Fonte: Adaptado de Ortiz (2011).

Neste Capítulo foram apresentados os conceitos referentes as FIGE e as mudanças que essas fontes têm produzido no setor produtivo que envolve a geração de energia elétrica. Além disso, são apresentados os potenciais solar e eólico das duas localidades estudadas nesta Tese, como também suas matrizes elétricas. No próximo Capítulo, serão apresentadas as revisões teóricas, seguindo um protocolo preestabelecido de revisão, referentes aos temas de previsão eólica e solar.

### 3 STATUS E TENDÊNCIAS DA PREVISÃO EÓLICA E SOLAR

Os métodos de previsão de séries temporais consideram as observações durante um determinado período, contendo informações sobre um padrão de comportamento. Embora várias técnicas já estejam consolidadas, novas abordagens ainda estão surgindo, sejam individualizadas ou em modelos híbridos, combinando duas ou mais técnicas. A construção do modelo de previsão requer uma análise detalhada do problema e pode ser complexa, dependendo do número de variáveis consideradas.

Os métodos aprendem o comportamento das séries analisadas e implementam o conhecimento adquirido para prever valores futuros, usando dados passados que podem vir da própria série ou de outras séries que influenciam o comportamento. As séries de previsões aplicadas aos recursos solar e eólico têm se tornado um desafio na área de mineração de dados. A previsão de valores futuros, com base em dados do passado, tem se tornado um assunto de especial interesse na academia e na indústria, com aplicações em planejamento de produção, desenvolvimento de matrizes elétricas e mercado de ações, entre outros.

As principais abordagens têm apresentado modelos físicos, estatísticos e de AM (Antonanzas *et al.* 2016; Liu; Sun, 2019). As metodologias de NWP usam imagens de satélite para prever o recurso solar e a geração FV, consistindo nos modelos físicos (Mathiesen; Kleissl, 2011; Peruchena *et al.*, 2017). Os modelos estatísticos são baseados em séries históricas, geralmente combinadas com outras metodologias autorregressivas (Bacher; Madsen; Nielsen, 2009), média móvel autorregressiva (Huang *et al.*, 2012) e média móvel autorregressiva integrada (Wu; Chan, 2012). Dentre os modelos de AM, as RNA se destacam com diferentes aplicações: a) Redes Neurais *Multi-Layer Perceptron* (MLP) (Ali Jallal *et al.*, 2020); b) *Radial Base Functions* (RBF) (Hu *et al.*, 2018; Jiang *et al.*, 2015); Redes Neurais Recorrentes (Jung *et al.*, 2020; Gao *et al.* 2019); Memória de longo prazo (LSTM) (Qing; Niu, 2018; Wang; Qi; Liu, 2019b).

Os métodos encontrados na literatura têm aplicações nos horizontes de curto (até sete dias), médio (mais de sete dias e até um mês) e longo prazo (após um mês) (Kumar Das *et al.*, 2018).

Diferentes técnicas de previsão solar propostas entre janeiro de 2015 e março de 2021 e técnicas de previsão eólica entre janeiro de 2018 e março de 2023 foram revisadas, com o objetivo de identificar o estado da arte e as tendências futuras. As revisões das análises solar e eólica têm períodos diferentes, pois foram ambas desenvolvidas de forma sequencial e a parte

solar compôs um artigo de revisão publicado no final de 2021. O desenvolvimento de metodologias na área de previsão solar e eólica é o foco de muitos pesquisadores em todo o mundo. Novas estratégias são formuladas e processos são atualizados a cada ano. Para evitar o uso de informações desatualizadas, foi estabelecida uma janela de pesquisa considerando pouco mais de cinco anos (no caso da área eólica) e pouco mais de seis anos (no caso da área solar).

Assim, os principais diferenciais da presente revisão de literatura são: a) Utilização de uma adaptação da *Systematic Literature Review (SLR)* para escolher e analisar publicações da área no período mencionado, considerando os principais autores, coleções e periódicos; b) Escolha dos artigos com base na variabilidade das técnicas; c) Classificação das metodologias aplicadas com base em diferentes critérios; e d) Definição de um perfil de tendência nas áreas de previsão solar e eólica, destacando as limitações e as vantagens das principais aplicações.

A revisão foi estruturada da forma descrita a seguir. Na seção 3.1 é apresentado o protocolo de revisão a ser aplicado para a elaboração do estado da arte dos artigos de previsão solar e eólica, de acordo com a abordagem: AM; modelos fenomenológicos; modelos estatísticos; e modelos híbridos. Na seção 3.2 é apresentada a revisão desenvolvida para o tema de previsão solar, subdividida em:

- subseção 3.2.1, que é apresentado o estado da arte das metodologias de previsão solar selecionadas;
- subseção 3.2.2, que é contemplada a classificação de cada metodologia de previsão solar analisada de acordo com o ano de surgimento das principais metodologias de previsão solar, os métodos de previsão de geração FV e de recurso solar por tipo de abordagem, o horizonte de previsão, o alvo da previsão e a escala de previsão espacial;
- subseção 3.2.3, em que as métricas de erro para avaliar a precisão dos métodos de previsão solar são discutidas; e
- subseção 3.2.4, em que são apresentadas as vantagens e limitações das abordagens analisadas nesta revisão e comenta as principais tendências para a área de previsão solar.

Na seção 3.3 é apresentada a revisão desenvolvida para o tema de previsão eólica, subdividida em:

- subseção 3.3.1, que é apresentado o estado da arte das metodologias de previsão eólica selecionadas;

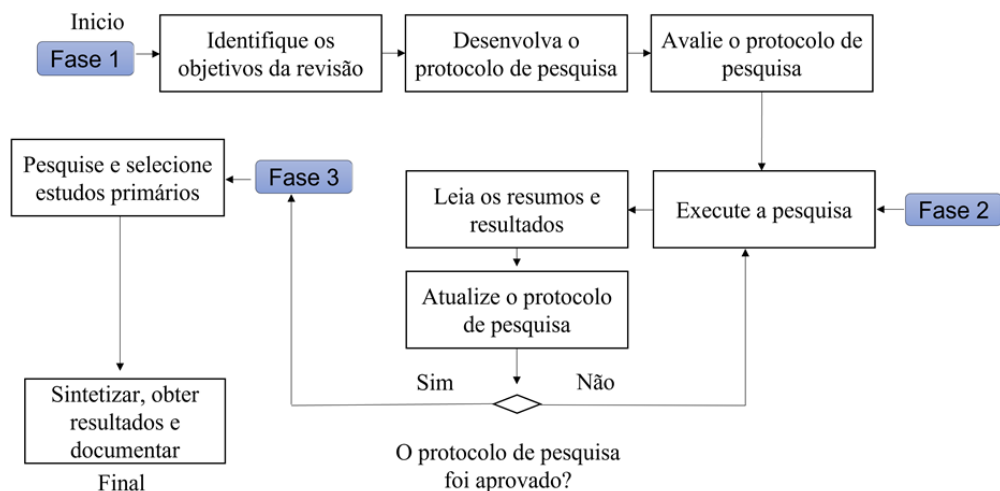
- subseção 3.3.2, que é contemplada a classificação de cada metodologia de previsão eólica analisada de acordo com o ano de surgimento das principais metodologias de previsão eólica, os métodos de previsão de geração eólica e do recurso eólico por tipo de abordagem, o horizonte de previsão, o alvo da previsão e a escala de previsão espacial;
- subseção 3.3.3, em que as métricas de erro para avaliar a precisão dos métodos de previsão eólica são discutidas; e
- subseções 3.3.4 e 3.3.5, em que são apresentadas as vantagens e limitações das abordagens analisadas nesta revisão e comentam as principais tendências para a área de previsão eólica.

Por fim, na seção 3.4 são apresentadas as considerações preliminares referentes às revisões sistemáticas realizadas sobre os temas de previsão solar e eólica.

### 3.1 Revisão Sistemática: Protocolo

Comumente aplicada em Engenharia de Software, na presente revisão é utilizada a *Systematic Literature Review (SLR)*, que estuda, de forma secundária, como identificar e interpretar de forma imparcial, passível de replicação, as evidências em relação a um tema específico de pesquisa (Kitchenham; Charters, 2007). Esta revisão aplica uma modificação do SLR, conforme proposto em Santos *et al.* (2017) (*Quasi-systematic Literature review - qSLR*). Na Figura 3.1 é mostrado o esquema do protocolo de revisão aplicado. Esta Tese implementa um protocolo de revisão próprio e norteia suas discussões em bases recentes.

Figura 3.1 – Fase de planejamento do *qSLR*



Fonte: adaptado de Santos *et al.* (2017).

Após a aprovação do protocolo, é realizada a busca dos estudos primários (critérios de inclusão e exclusão) até o total de artigos a serem analisados e obtido o relatório. As questões de pesquisa utilizadas foram as seguintes: 1. Quais são as principais abordagens existentes para prever os recursos solar e eólico ou para a geração FV e eólica? 2. Quais são as principais metodologias implementadas na literatura científica dos últimos 5 anos? 3. Quais métricas foram implementadas para medir a qualidade das diferentes aplicações e quais métodos se destacaram por serem mais precisos? 4. Como são classificadas as metodologias? Essas questões objetivas identificam os horizontes de previsão mais comuns, sejam as aplicações regionais ou locais, e a abordagem aplicada (física, estatística, aprendizado de máquina ou uma combinação de modelos compondo um modelo híbrido).

Na etapa de seleção, os trabalhos são excluídos se: a) não apresentarem proposta replicável; b) não utilizarem métricas e metodologias para comparar e validar as aplicações; c) não utilizarem uma metodologia que esteja dentro das abordagens física, estatística, de AM ou uma combinação dessas abordagens; d) não preverem os recurso solar e eólico ou a geração FV e eolielétrica; e) não forem publicados em periódico revisado por pares. Adicionalmente, foi dada nota aos artigos recolhidos na primeira fase, a partir de um formulário de avaliação da qualidade, utilizando as seguintes questões:

- Q1 - Existe uma descrição sistemática da técnica? (1 pt)
- Q2 - Existe alguma descrição de restrições ou condições de aplicabilidade da proposta? (1 pt)
- Q3 - O artigo usa métricas consolidadas para avaliar a proposta? (1 pt)
- Q4 - O artigo descreve o uso da proposta em diferentes regiões ou é específico? (1 pt)
- Q5 - As hipóteses estão explicitamente descritas no artigo? (1 pt)

Considerando o protocolo definido previamente, a definição do quantitativo dos artigos a seguirem sendo revisados ficou da seguinte forma: a) Na análise solar, em um universo de 400 artigos coletados inicialmente, um total de 140 foram selecionados; e b) Na análise eólica, em um universo de 230 artigos coletados inicialmente, um total de 89 foram selecionados.

Todos os artigos selecionados, seja na revisão eólica ou solar, obtiveram notas acima de 3, considerando os critérios de Q1 a Q5. Artigos duplicados foram excluídos (na análise solar

foram excluídos um total de 28 artigos e na análise eólica foram excluídos um total de 32 artigos). Uma explicação dos artigos selecionados, por tipo de abordagem, é descrita a seguir.

### 3.2 Metodologias de Previsão Solar

A geração FV é caracterizada pela intermitência, cujo impacto precisa ser reduzido para garantir um fornecimento de eletricidade adequado e confiável. Previsões de geração FV com alta precisão podem reduzir o custo líquido de geração (Lima *et al.*, 2020) e os impactos na segurança da rede. Além disso, os benefícios da previsão do recurso solar podem ser relevantes em mercados que experimentam desequilíbrio de energia, trazendo redução nos recursos de *backup*. Assim, metodologias que envolvem previsão de curto prazo podem ser ferramentas importantes para manter o equilíbrio entre demanda e oferta (Kaur *et al.*, 2016; Pedro; Coimbra, 2015a).

Muitas metodologias de previsão apresentam o desafio de obter dados solares confiáveis e suficientes para uma aplicação específica. Um novo pacote *R - SolarData* é apresentado em Yang (2018), propondo cinco conjuntos de dados principais, incluindo: o modelo físico solar versão 3 do *National Renewable Energy Laboratory* (NREL); a rede de medição solar NREL Oahu; a rede de radiação de superfície da *National Oceanic and Atmospheric Administration* (NOAA); o fator de turbidez *SODA Linke*; e a missão de topografia de radar de ônibus espacial da *National Aeronautics and Space Administration* (NASA). Trabalhos exploratórios desse tipo podem ser encontrados na literatura e representam um avanço na análise de dados e disponibilidade de dados online.

Além da dificuldade em obter dados confiáveis, outra limitação importante para as previsões solares envolve o clima local e as condições do ar. Diferentes filtros são propostos em Nobre *et.al.* (2016) para entender o comportamento da irradiação solar no solo em Cingapura: um filtro de umidade remove as condições com umidade acima de 80%, o Filtro de Fração de Irradiância Difusa remove as condições de alta cobertura de nuvens sem chuva, e o *Clear Sky Irradiance Band Filter* avalia os dias sem nuvens, utilizando a metodologia proposta por Yang *et al.* (2014). Os autores concluem que situações com muita neblina ou má qualidade do ar resultam em uma queda no desempenho do módulo FV de até 25%.

Para a estimativa do potencial de aplicações solares, a existência de um mapeamento de dados que facilite a avaliação dos recursos disponíveis é essencial. Mapas de recursos solares são propostos em Yang e Gueymard (2019) a partir da modelagem de processos gaussianos, que

é usada para combinar duas fontes de dados de forma otimizada. Outro aspecto importante é a investigação do melhor padrão de referência a ser utilizado para comparação nas aplicações de previsões solares em diferentes horizontes.

Uma análise do desempenho das previsões solares operacionais em um horizonte diário é encontrada em Yang (2019c), usando dados horários de 32 estações ao longo de um ano. Cinco previsões de referência foram testadas: duas de climatologia (Clim1 e Clim2), duas de persistência (Pers1 e Pers2) e a combinação linear entre os dois tipos (ClimPers). ClimPers pode ser adequado para referência em previsões solares para o dia seguinte, mas se outras orientações precisarem ser seguidas, como discriminação maximizada, por exemplo, outros métodos podem ter um desempenho melhor.

A previsão da irradiação solar envolve muitas incertezas, em decorrência das características da série solar e da alta volatilidade do clima. Existem diversos métodos para auxiliar na tarefa de desenvolver previsões de séries temporais, como os modelos derivados de estatísticas, de RNA e de outras técnicas de inteligência computacional (IC).


As previsões de energia solar de curto prazo podem ser utilizadas no planejamento da operação de sistemas FV, solares térmicos ou híbridos, visando otimizar o uso do recurso solar (Kumar Das *et al.*, 2018). De acordo com Jung *et al.* (2020), os métodos de previsão de geração FV podem ser diretos ou indiretos: modelos diretos, como o nome sugere, usam previsão de geração FV; modelos indiretos inicialmente preveem a irradiação solar e, posteriormente, uma conversão numérica ou analítica é usada para estimar a potência FV. Em Wang, Qi e Liu (2019a), é encontrada uma classificação da escala de previsão espacial, que pode ser dividida em campo único e previsão regional.

Por meio de pesquisas no Portal de Periódicos da Capes do Ministério da Educação e no *IEEE Xplore*, com os seguintes filtros, foram elaborados os gráficos das Figuras 3.2 a 3.5. Os parâmetros de pesquisa foram: 1. Tipo de publicação: artigo; 2. Período de avaliação: janeiro de 2015 a março de 2021; 3. Tipo de periódico: revisado por pares; e 4. Área de pesquisa: previsão solar.

Na Figura 3.2 são mostrados os principais autores da área de previsão solar no período e a quantidade de seus trabalhos; na Figura 3.3 são apresentadas as principais coleções e a quantidade de artigos da área; na Figura 3.4 são mostrados os principais periódicos e a quantidade de trabalhos na área; e na Figura 3.5 são apresentados os continentes e o número de contribuições na área.




Figura 3.2 – Informações gerais a respeito de artigos sobre previsão solar revisados por pares, publicados entre janeiro de 2015 e março de 2021: Autores



Fonte: Próprio autor.

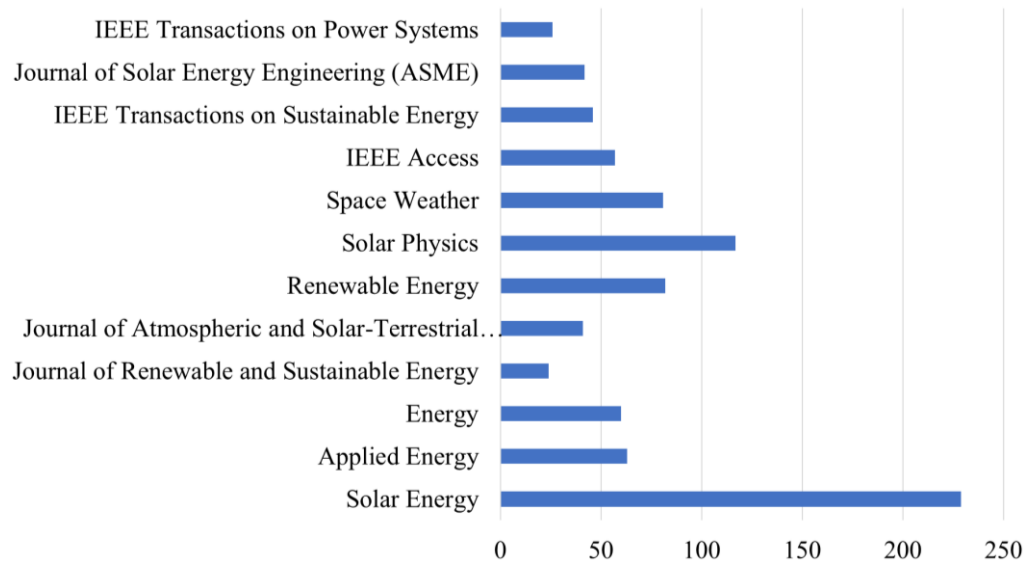
Figura 3.3 – Informações gerais a respeito de artigos sobre previsão solar revisados por pares, publicados entre janeiro de 2015 e março de 2021: Coleção



Fonte: Próprio autor.


A coleção da *Elsevier* apresenta o maior número de artigos da área, incluindo publicações das revistas *Solar Energy*, *Energy* e *Applied Energy*. Os três principais autores da área são Yang, Dazhi; Kleissl, Jan; e Wang, Fei. Em relação aos continentes, os destaques são América do Norte (principalmente EUA), Europa (principalmente Espanha e França) e Ásia (principalmente Malásia e China).

Figura 3.4 – Informações gerais a respeito de artigos sobre previsão solar revisados por pares, publicados entre janeiro de 2015 e março de 2021: Jornal



Fonte: Próprio autor.

Figura 3.5 – Informações gerais a respeito de artigos sobre previsão solar revisados por pares, publicados entre janeiro de 2015 e março de 2021: Continentes



Fonte: Próprio autor

### 3.2.1 Estado da Arte

#### 3.2.1.1 Previsão do Recurso Solar Baseada em Aprendizado de Máquina

Modelos baseados em AM geraram uma grande coleção de artigos sobre previsão solar nos últimos anos (Mert Yagli; Yang; Srinivasan, 2019), sendo considerada uma abordagem popular para previsão solar no horizonte de horas. A precisão do modelo depende de uma variedade de fatores, incluindo tempo ou clima. Uma metodologia para avaliar modelos de

previsão solar baseados em AM é encontrada em MertYagli, Yang e Srinivasan (2019). O desempenho preditivo para 68 algoritmos de AM é testado usando imagens derivadas de satélite.

O método *k-Nearest Neighbor Ensemble* (kNNEn) é proposto por Chu e Coimbra (2017), fornecendo previsões adaptativas e arbitrárias da Função de Densidade de Probabilidade (FDP) aplicadas para prever a Irradiação Normal Direta (IND) intra-hora usando dados de irradiância difusa e informações de cobertura de nuvens. O modelo apresenta desempenho superior aos modelos de persistência e de probabilidade gaussiana em um horizonte maior que 5 minutos com *Forecast Skill Score* (FSS) de 14,9%. Um método de similaridade de previsão solar baseado em *k-Nearest-Neighbors* (kNN) é encontrado em Boilley *et al.* (2016) para prever a irradiância solar (horizonte diário). Usando dados de longo prazo do HelioClim-3, os autores validam a aplicação por meio de *Baseline Surface Radiation Network* (BSRN).

Qing e Niu (2018) propõem um modelo treinado usando LSTM para previsão de irradiação solar diária em Cabo Verde. O algoritmo é comparado com persistência, regressão linear de mínimos quadrados e redes neurais multicamadas *feedforward* usando métodos de algoritmo de retropropagação (RRNM). Um grupo de modelos de *Deep Learning* é proposto em Prado-Rujas *et al.* (2021) para prever a irradiância solar. Os modelos são utilizados para dar mais flexibilidade e robustez à proposta, visando dar continuidade às previsões na ausência de sensores que possam apresentar falhas no dia a dia. Os modelos são treinados em diversos locais e, na sequência, mapas de irradiância são utilizados nas previsões por meio do LSTM.

Yang (2019) implementa um método chamado *Naive Bayes Classifier* (NBC) relacionando climatologia, persistência e sua combinação convexa ótima. A combinação convexa de climatologia e persistência pode ser usada como um *benchmark* universal para previsões solares determinísticas.

Incertezas em relação aos modelos de previsão de irradiação horizontal global (IHG) são avaliadas por meio de AM em Voyant *et al.* (2017b), onde os modelos testados utilizam dados de quatro estações meteorológicas na França. As principais incertezas dos métodos de previsão horária estão relacionadas aos seguintes pontos e percentuais: a) erro de medição (1%); b) erro de amostragem (5%); c) erro inerente (10%); e d) erro de horizonte (entre 5 e 20%).

Pedro e Coimbra (2015a) usam kNN para prever IHG e IND e os intervalos de previsão de incerteza correspondentes. Os autores preveem o intervalo de previsão (IP) que "é uma estimativa de um intervalo no qual um valor medido futuro cai, dado um limite inferior e superior". Os IPs fornecem informações sobre a incerteza nas previsões e são importantes para

o planejamento operacional. As imagens do céu não trazem melhorias significativas na previsão, porém parâmetros derivados das imagens contribuem quando há nebulosidade.

Considerando a variabilidade meteorológica de Ajaccio (ilha francesa), Tilos (ilha grega) e Odeillo (França), Fouilloy *et al.* (2018) testam onze métodos de previsão de irradiação solar no horizonte de 1 a 6 horas. O modelo de persistência mostra o pior desempenho. Para uma alta variabilidade (Odeillo), os melhores desempenhos são obtidos com modelos de aprendizagem por *ensemble*.

Em Benali *et al.* (2019), os métodos de inteligência artificial (RNA e RF) são comparados para prever os três componentes da irradiação solar: IHG, IND e Irradiação Solar Horizontal Difusa (IHD) na França. Horizontes de previsão entre 1 e 6 horas são testados. Em todas as aplicações, RF mostra os melhores resultados.

Li *et al.* (2016) aplicam os métodos de regressão *Hidden Markov Model* (HMM) e SVM para prever a irradiância solar em sistemas FV. Os modelos são testados em diferentes condições climáticas: nublado repentino; ensolarado; nebuloso; e chovendo. A regressão SVM tem um desempenho melhor do que o HMM em todas as condições climáticas.

Modelos de RNA são projetados para produzir previsões solares diárias usando dados terrestres e exógenos em Aguiar *et al.* (2016). Os dados são obtidos a partir das seguintes fontes: a) dados terrestres de duas estações de medição na ilha de *Gran Canaria*; b) dados de IHG via satélite (do *Helioclim-3*); c) dados sobre irradiação solar e cobertura total de nuvens do *European Center for Mid-Range Meteorological Forecasts* (ECMWF). A combinação de dados de satélite e ECMWF fornece os melhores resultados de previsão para ambas as estações de medição. Em algumas aplicações, o nRMSE aumenta com o horizonte de previsão.

McCandless, Haupt e Young (2016) usam MLP, dados numéricos de análises meteorológicas e observações de irradiância solar como entrada para prever o índice de claridade em vários locais em Sacramento, Califórnia. O método RNA dependente do regime reduz o MAE da previsão do índice de clareza em 5,9%, 21,1% e 29,3% para períodos de 60 min, 120 min e 180 min, respectivamente.

Ali Jallal *et al.* (2020) usam uma RNA com diferentes métodos de treinamento (*conjugate gradient* (CG), *Levenberg-Marquardt* (LM) e *Resilient Backpropagation* (RP)) para prever a irradiação solar de curto prazo (minutos) em Marrocos. Uma previsão de 99,13% é alcançada na fase de teste para prever os dados de CG nos próximos seis anos (de 2009 a 2014).

Lan *et al.* (2018) usam a técnica *Ensemble empirical mode decomposition* (EEMD) com *self-organizing map - back propagation* (SOM-BP) para prever a irradiação solar em um

horizonte horário. O método proposto obtém melhores resultados do que aplicações com RBF e *Back Propagation* (BP) e pode prever com precisão a irradiação solar e rastrear variações do IHG real.

Considerando a previsão da irradiação solar com 10 minutos de antecedência e as condições de operação, Rahmann, Mayol e Haas (2018) propõem uma estratégia de controle com o objetivo de minimizar os efeitos do sombreamento na operação de usinas FV. Para cada uma das três zonas diferentes sob investigação, quatro RNA são treinados para prever a geração da planta FV.

MertYagli *et al.* (2020) avaliam a qualidade das previsões solares (horizonte horário) usando dois tipos de dados: a) IHG baseado em satélite; e b) IHG com base em dados derivados de satélite com correção de enviesamento, usando modelos de AM. Em termos de nRMSE, os modelos apresentam resultados semelhantes. Pedro *et al.* (2018b) avaliam técnicas de previsão para irradiação IHG e IND usando métodos AM: kNN e gradiente *boosting* (GB). Usando a *Prediction Interval Normalized Averaged Width* (PINAW) e as previsões probabilísticas como referência, kNN mostra  $PINAW \leq 10,1\%$  para IHG e  $PINAW \leq 15,4\%$  para IND; GB mostra  $PINAW \leq 11,7\%$  para IHG e  $PINAW \leq 17,5\%$  para IND.

Um modelo de previsão *wavelet* é proposto em Zhu *et al.* (2017), usando o índice de céu claro como entrada, com o objetivo de estimar o IND horário sob qualquer condição de céu. Uma série de índice de céu claro é decomposta pela tecnologia *wavelet* para obter quatro subséries com frequências diferentes. O modelo de previsão *wavelet* superou o desempenho de outros modelos de previsão.

Heo *et al.* (2020) propõem um modelo CNN usando conjuntos de dados de terreno para estimar e mapear a irradiação solar anual. A proposta inclui dados topográficos obtidos em um *digital elevation model* (DEM) visando selecionar locais adequados para plantas FVs. A partir desses dados, padrões são reconhecidos para modelar a relação não linear com o potencial de irradiação solar da região.

Usando *Adaptive Neuro-Fuzzy Inference Systems* (ANFIS) e dados de irradiação solar por um período de 9 anos coletados em estações terrestres, uma metodologia para prever a IHG com o objetivo de estimar o potencial solar na Tailândia é proposta em Nirudh e Somchat (2019). O modelo ANFIS apresentou bom desempenho. Mudanças globais na irradiância horizontal são previstas em Kamadinata, Ken e Suwa (2020) usando RNA. A metodologia proposta atingiu um erro de previsão de 40% com valores limites de 50 a 100 W/m<sup>2</sup> para grandes aumentos e diminuições nas previsões de irradiância solar.

Uma estratégia chamada *multi-step forecasting* (MSF) é aplicada em Wen *et al.* (2021). DL é usado para prever os valores de IHG em várias previsões dentro do horizonte de previsão com a maior resolução temporal. A estratégia de MSF pode ser aplicada no controle de taxa da rampa de potência FV e foi demonstrada com um FSS de 17,7% e uma taxa de controle superior de 98,9% quando comparada ao controle convencional.

### 3.2.1.2 Previsão da Geração FV Baseada em Aprendizado de Máquina

Vaz *et al.* (2016) propõem uma estratégia de previsão para a produção de eletricidade de uma planta FV no horizonte horário e mensal. Uma arquitetura de RNA é implementada usando o modelo *Non-linear Autoregressive with Exogenous Inputs* (NARX), considerando não apenas dados climáticos locais, mas também medições de usinas FVs vizinhas, aumentando a precisão da previsão. Uma metodologia baseada em RNA e um AnEn para gerar 72 h de previsão da geração FV determinística e probabilística é encontrada em Cervone *et al.* (2017). A metodologia mostra uma escala extremamente boa para aplicações massivamente paralelas.

Um modelo de previsão FV para um dia e uma hora à frente é desenvolvido por Hossain *et al.* (2017) baseado na abordagem *Extreme Learning Machine* (ELM). O modelo proposto utiliza dados de potência de uma usina FV e parâmetros meteorológicos registrados em três usinas FVs conectadas à rede no telhado da Universidade da Malásia. Um método alternativo de previsão de intervalo de potência FV multimodelo que considera a distribuição sazonal das características de flutuação de potência é proposto em Han *et al.* (2019). O modelo aplicado é o ELM. O método multimodelo sazonal proposto é comparado com o modelo único anual. Para todas as estações, o modelo proposto é superior ao modelo único anual.

Liu e Sun (2019) propõem modelos utilizando algoritmos *recurrent neural network* (RNN) do tipo LSTM para prever a potência FV no horizonte diário para diferentes condições climáticas. Para as condições climáticas ideais, os dados previstos pelo NWP e fatores sazonais são usados como entradas. Para condições não ideais, são usados dados do *discrete gray model* (DGM). O modelo é testado para as quatro estações do ano, obtendo bom desempenho. Jung *et al.* (2020) usam um modelo RNN com memória de longo prazo para prever a produção de eletricidade FV na Coreia do Sul. O modelo generaliza dados de 164 usinas FVs amplamente espalhadas pelo país, e um único modelo de previsão é integrado.

Hu *et al.* (2018) aplicam um modelo de RNA para previsão da geração FV de curto prazo (minutos). A metodologia é dividida em três etapas: nas duas primeiras fases são analisadas a cobertura de nuvens e as características das nuvens. Na terceira etapa, é proposta uma RBF, e sua previsão de potência é comparada com um modelo Auto Regressive (AR). Em termos de MAPE, o RBF apresenta melhor rendimento que o AR.

Uma metodologia baseada em Algoritmos Genéticos (AG) é aplicada em Tucson, Arizona, para prever a geração solar e a absorção de eletricidade (Alfulayyih; Gwesh, 2019). O objetivo é planejar a captação e armazenamento da geração solar visando um fornecimento de energia estável ao longo do ano, 100% baseado em geração solar. A lógica *fuzzy* é usada em Sridharan *et al.* (2018) para prever a potência de saída FV. Quatro funções de pertinência são usadas como entrada: baixo (L), baixo médio (Lm), médio alto (MH) e alto (H). A porcentagem de erro e precisão encontrada é de 5,62% e 94%, respectivamente.

Uma *cascade-forward back propagation artificial neural network* (CFNN) para prever a corrente de saída de um sistema FV de 1,4 kWp localizado em Sohar, Omã é investigada em Ameen *et al.* (2015). Dois anos de dados são utilizados, com o modelo proposto obtendo MAPE de 7,08 %, MBE de 0,21 A (4,98 %) e RMSE de 0,315 A (7,5 %).

### 3.2.1.3 Modelos Fenomenológicos (Previsão Numérica do Tempo) para a Previsão do Recurso Solar

Modelos NWP têm sido amplamente utilizados para previsão solar em horizontes de 1 ou 3 horas até 72 horas, com resultados razoáveis. No entanto, como esses modelos geralmente carregam um viés sistemático, previsões desse tipo, na maioria das vezes, precisam de pós-processamento para melhorar o desempenho (Yang, 2019a). Além disso, os métodos NWP são desenvolvidos principalmente para céu claro e áreas abertas e não podem ser aplicados diretamente em áreas urbanas onde existem diferentes tipos de obstáculos que podem interferir na incidência de radiação.

Alguns dos equívocos comuns e aplicações úteis do *Kalman Filter* (KF) para o pós-processamento de NWP são comentados em Yang (2019a). O filtro altera o horizonte de previsão do dia seguinte de NWP para uma hora à frente, tornando o filtro irrelevante para aplicativos de horizonte diário; além disso, pode ser aplicado a um conjunto ordenado de previsões analógicas. O uso de observações de satélite geostacionário em NWP para produzir previsões de curto prazo de rampas de irradiação solar é descrito em Miller *et al.* (2018). A

altura das nuvens, ventos variáveis no espaço/tempo, geometria solar e suas sombras em modelos de terreno variável são combinados para a previsão.

*Weather Research and Forecasting* (WRF) é aplicado em Aryaputera, Yang e Walsh (2015) para prever a irradiância solar em Cingapura. A aplicação é comparada com o modelo de persistência, *Seasonal Autoregressive Integrated Moving Average* (SARIMA) e *exponential smoothing* (ETS). O WRF supera o SARIMA e combinado com o ETS apresenta melhores resultados que os modelos individualizados. Um modelo WRF é desenvolvido em Huva, Verbois e Walsh (2020) para simular a atmosfera de Cingapura até 3 km de resolução, usando observações para restringir o estado do modelo a uma evolução estática (*three-dimensional variational data assimilation technique* - 3DVAR) ou temporal (*four-Dimensional Variational Data Assimilation Technique* - 4DVAR). Os dados são coletados no *Singapore Solar Energy Research Institute* (SERIS) por meio de 25 estações de monitoramento terrestre.

O uso de *Large Eddy Simulations* e um *3D Radiative Transfer Model* na produção de imagens do céu, nuvens virtuais e medições de irradiação solar é analisado em Kurtz, Mejia e Kleissl (2017). Uma ferramenta *sky imager testbed* permite a validação dos resultados de várias etapas do algoritmo de previsão do *sky imager* e a avaliação da origem dos erros remanescentes. Em horizontes mais longos, a suposição de advecção de nuvens congeladas para prever futuras posições de nuvens reduz a precisão da previsão.

Estimativas de movimentos densos e trajetórias de pontos são encontradas em Chow, Chow, Belongie e Kleissl (2015), usando previsões de *variational optical flow* (VOF). As previsões de VOF são comparadas com as previsões do método de correlação cruzada (CC), obtendo-se erros médios mais baixos. Nuvens instáveis reduzem a precisão das previsões, e tais condições de instabilidade devem ser consideradas na análise.

Uma análise da 3DVAR é utilizada em Sahu, Yang e Kleissl (2018) visando melhorar a inicialização em modelos NWP e previsões IHG e Índice de céu claro (ICC). Observações meteorológicas das redes *in situ* da superfície e do ar superior ao longo da costa sul da Califórnia são usadas como entradas (horizonte horário). A ausência de conteúdo de água líquida no modelo de inicialização faz com que as nuvens se desenvolvam lentamente resultando em uma subestimação da cobertura de nuvens estrato-cúmulo em relação à realidade.

Uma previsão de nuvens costeiras do tipo *Stratocumulus* (Sc) usando o *Geostationary Operational Environmental Satellite* (GOES) para melhorar as previsões diurnas de dissipação de nuvens Sc é proposta em Wu, Clemesha e Kleissl (2018). Essas previsões são importantes porque os vetores de movimento de nuvens (VMN) de satélite não preveem com precisão como



um Sc se move e se dissipa. A metodologia proposta supera o modelo persistente em 9 das 11 estações e o modelo VMN em 7 das 11 estações.

O impacto do teor de água líquida da atmosfera na partida do WRF é analisado em Yang e Kleissl (2016), usando um *Well-mixed Preprocessor* (WEMPP); e b) *Cloud Data Assimilation* (CLDDA). A primeira metodologia utiliza a camada limite mista para obter o teor de água que entra na *North American Mesoscale* (NAM); o segundo formula o campo de nuvem do modelo inicial consistente com as observações, usando dados *Cooperative Institute for Meteorological Satellite Studies* (CIMSS GOES). O objetivo é prever nuvens Sc, que determinam a variabilidade dos recursos solares e a irradiância solar.

Uma caracterização local usando o ICC para definir as condições meteorológicas e produzir uma parametrização da variabilidade solar intradiária é proposta em Lauret *et al.* (2016). Esta caracterização é aplicada para melhorar um ECMWF, podendo contribuir para melhorias e aumentar a dinâmica das previsões de irradiância solar. Um modelo baseado na análise de desafios práticos de *empirical mode decomposition* (EMD) para previsão de velocidade do vento e irradiação solar é desenvolvido em Wang e Wu (2016).

Um sistema de rastreamento de nuvens com o objetivo de prever eventos climáticos com base em imagens do céu, em situações de sol ou nublado, é proposto em Cheng (2017). As nuvens de rastreamento, mesclagem e divisão são tratadas verificando pares correspondentes de pontos de recursos entre diferentes *clusters*. Métodos para reduzir a dimensionalidade para obter conjuntos robustos de recursos que não apenas melhoram a precisão da previsão, mas também fornecem resultados mais interpretáveis e consistentes, são investigados em García-Hinde *et al.* (2018). A redução de dimensionalidade em geral é uma ferramenta útil para melhorar o desempenho, além de facilitar a interpretabilidade dos resultados.

Um modelo baseado em NWP para reduzir incertezas de previsão IND é proposto em Nonnenmacher, Kaur e Coimbra (2016), visando: a) Correções do modelo de céu claro; e b) Realizar previsões para melhorar as previsões extraíndo informações de erros estruturados. A incerteza de previsão, usando um método NWP assumindo normalidade multivariada de índices de clareza transformados por mapeamentos não lineares, é analisada em Murata, Ohtake e Oozeki (2018). As taxas de acerto calculadas a partir de vários intervalos de confiança, usando a função de probabilidade normal multivariada, estão próximas das taxas modeladas para cada nível de confiança de intervalo único.

Uma nova metodologia é proposta em Akarslan e Hocaoglu (2017), por similaridade (procura-se um dia semelhante ao dia de previsão) e utilizando dados de irradiância

extraterrestre, para a previsão horária da irradiação solar na Turquia; valores nRMSE de previsão de 18 e 19% são encontrados.

#### 3.2.1.4 Modelos Fenomenológicos (Previsão Numérica do Tempo) para a Previsão da Geração FV

De acordo com Fen *et al.* (2015), existem muitos *links* em um sistema FV real e em todos os estágios de conversão, erros sistemáticos podem ser introduzidos ao usar os Modelos Fenomenológicos. Sistemas FV de grande porte integrados em edifícios podem ter diferentes inclinações, arranjos e orientações tornando a previsão mais complexa. Um modelo numérico de simulação de rede para prever a produção líquida FV no Japão é desenvolvido em Inage (2017). Uma Equação de advecção estima a velocidade e o crescimento das nuvens; a produção da rede FV e o movimento das nuvens são simulados numericamente.

Um método baseado na otimização de mínimos quadrados de NWP é encontrado em Larson, Nonnenmacher e Coimbra (2016). O estudo é desenvolvido em San Diego, EUA, e prevê a potência FV média horária para o dia seguinte em duas usinas de 1 MWp sem rastreamento.

Uma técnica de previsão de geração solar e eólica é desenvolvida usando o sistema de gerenciamento de banco de dados de código aberto - MySQL em Pedro, Lim e Coimbra (2018a). O RMSE e o FSS são calculados todos os dias, refletindo o desempenho geral, variações sazonais para os três modelos de previsão e quatro horizontes de previsão em função do tempo, que é proporcional ao tamanho do banco de dados.

#### 3.2.1.5 Previsão do Recurso Solar Baseada em Modelos Estatísticos

Um modelo de *complete-history persistence ensemble* (CH-PeEn) é proposto em Yang (2019b) como um método de *benchmarking* universal para previsão solar probabilística. A metodologia *continuous ranked probability score* (CRPS) depende apenas da localização e resolução temporal dos dados. Dois métodos paramétricos de previsão probabilística para prever a irradiação solar usando distribuições de energia beta e bilateral são implementados em Fatemi, Kuh e Fripp (2018). Os testes são realizados em Elizabeth City - Carolina do Norte, Los Angeles - Califórnia e LaOla - Havaí. As energias beta e bilateral são aplicadas

individualmente e combinadas; em seguida, ambas são comparadas com distribuição marginal empírica e modelo PeEn. O método combinado apresenta bom desempenho.

Um método de *spatiotemporal kriging* é encontrado em Aryaputera *et al.* (2015), fornecendo irradiância solar de curto prazo em locais com e sem estações de medição. A validação cruzada é usada para avaliar o desempenho, usando 17 estações no Havaí. A metodologia *Lasso* é aplicada em Yang *et al.* (2015a) para previsão de curto prazo da irradiação solar no Havaí. O método é usado de forma iterativa para identificar os preditores mais adequados para um determinado tempo. A aplicação apresenta resultados superiores à persistência e outros métodos de séries temporais.

A técnica probabilística *ensemble model output statistics* (EMOS) é utilizada em Yang (2020) para adaptação local e correção de variações no conjunto amostral, que pode ser super ou sub disperso em estimativas de irradiância de grade derivadas de satélite e reanálises. A técnica se mostrou superior em estimativas probabilísticas e determinísticas.

Vários métodos para prever a irradiância ao nível do solo são comentados em Reikard, Haupt e Jensen (2017): WRF, *Dynamic Integrated Forecast* (DICast) e *Autoregressive Integrated Moving Average* (ARIMA), considerando horizontes de previsão de 15 minutos a 4 horas nos EUA. Em todos os horizontes horários, ARIMA e *DICast* obtêm os melhores resultados. Uma avaliação de modelos preditivos no domínio da frequência é proposta em Reikard e Hansen (2019). Dados reais de irradiância em céu claro e índices de claridade vêm de seis locais nos EUA; são utilizados métodos como persistência, regressões de nível, ARIMA e um modelo de domínio da frequência, baseado na transformação ARIMA de Fourier. O modelo de persistência apresenta os melhores resultados.

Cinco modelos semiempíricos são propostos em Akarlan, Hocaoglu e Edizkan (2018) para diferentes regiões da Turquia, mostrando as características: (1) a última variação na irradiância solar é aproximadamente a mesma para a próxima hora; (2) além da amostra de irradiância solar passada, é usado o índice de claridade; (3) o valor futuro da irradiância extraterrestre pode ser calculado porque este valor é determinístico; (4) analisa-se a influência das variações na irradiância solar extraterrestre, o comportamento estocástico da natureza e o índice de claridade; e (5) a variação da irradiância solar é considerada proporcional à variação correspondente na irradiância extraterrestre.

Uma metodologia baseada no KF com o objetivo de prever séries globais de irradiação solar sem a necessidade de dados históricos é proposta em Voyant *et al.* (2017a). O modelo é comparado com os modelos ANN, NWP e AR; para o horizonte de 1 h o resultado é considerado

competitivo. Modelos estocásticos para a previsão de irradiação solar e geração FV são propostos em Dong *et al.* (2020), usando funções *uncertain basic* (UB) (*Gaussian* (UBG), *Laplace* (UBL) e *Uniform* (UBU)) e modelos estocásticos (algoritmo *expectation maximization* (EM) combinado com KF (EM-KF) e *Prediction Error Minimization* (PEM)). Para irradiação solar, os melhores resultados para horizontes de 1, 5 e 50 minutos são UBU, UBG e PEM, respectivamente; para geração FV, os melhores resultados para horizontes de 1, 5 e 50 minutos são UBU, UBG e UBL, respectivamente.

Dados de irradiação solar inclinada e os efeitos desta inclinação e orientação sobre a precisão da previsão da geração FV no Havaí são analisados em Amaro e Silva e Brito (2019). Um modelo linear *Autoregressive with Exogenous Inputs* (ARX) é usado para previsão espaço-temporal de curto prazo, junto com um conjunto de dados solares distribuídos espacialmente, que é decomposto antes de ser aplicado à previsão ARX. São testados quatro diferentes cenários (inclinações). A capacidade de previsão é sensível ao conjunto de inclinação e orientação com entradas apenas no telhado ou fachada.

A metodologia de *Box & Jenkins* para previsão de médias diárias de velocidade do vento, irradiação solar, temperatura ambiente e temperatura do módulo FV é investigada em Bin Shams *et al.* (2016). O modelo aplicado para prever a irradiação solar é o ARIMA e a aplicação apresenta um MAPE de 6,38%.

### 3.2.1.6 Previsão da Geração FV Baseada em Modelos Estatísticos

“A estatística não modela os processos físicos, mas prevê diretamente a produção de energia usando os dados históricos durante a operação realista” (Fen *et al.*, 2015). Método estatístico que usa análise fatorial e análise de regressão múltipla é aplicado em Fen *et al.* (2015) para estimar a produção diária FV em Wuhan-China usando séries históricas de geração elétrica, dados meteorológicos e ambientais. Os dados vêm de um sistema FV conectado à rede no telhado da Universidade de Huazhong.

A incerteza introduzida pelo erro de previsão e um método capaz de gerar um sinal de erro artificial são considerados em Giammanco *et al.* (2016), usando a distribuição de *Gauss-Lorentz*. O objetivo é avaliar a capacidade de armazenamento que deve suportar uma planta FV real de 990 kWp na Itália e a probabilidade de reduzir uma fração do erro de previsão do MAE, dado em função da capacidade de armazenamento instalada. Uma metodologia baseada em *Gaussian Processes* (GP) para previsão de consumo de eletricidade, potência FV e demanda

líquida é proposta em van der Meer *et al.* (2018). Modelos dinâmicos e estáticos são testados e os modelos propostos são comparados com o ARIMA, que apresenta melhor desempenho.

O método *maximum Lyapunov exponent* (MLE) é proposto em Zheng *et al.* (2018) para a previsão da geração FV de curto prazo na China, visando auxiliar a operação de uma microrrede. Os dados são coletados de um sistema em um telhado da Universidade de Hangzhou Dianzi, na China, e divididos em dias ensolarados, nublados e chuvosos. O método MLE apresenta um bom desempenho quando comparado a um modelo AR.

Modelos caixa-preta, lógica *fuzzy* e um modelo estatístico semiparamétrico inspirado fisicamente (*Generalized Additive Model*, GAM), baseado em suavização de *splines*, para a previsão horária da potência FV são testados em Paulescu *et al.* (2017). Os modelos são comparados com o modelo linear simples testado no âmbito da *European Cooperation in Science and Technology* (COST). Os três métodos são testados em usinas FVs na Catânia e Milão (Itália), com o GAM apresentando o melhor desempenho.

Um modelo estatístico de IP para geração FV é proposto em Ni *et al.* (2017). O modelo usa uma abordagem de *lower upper bound estimation* (LUBE) combinada com ELM para construir IP (ELUBE). Vários modelos são testados e comparados: (PeEn), modelo ELUBE e quatro modelos de conjuntos baseados em ELUBE: *mean-value-based weighted average* (MAWA), *particle swarm optimization weighted average* (PSO-WA), *Differential Evolution-based weighted average* (DEWA) e *improved Differential Evolution-based weighted average* (IDEWA). Os modelos são avaliados pelas métricas *prediction interval coverage probability* (PICP), pontuação de *Winkler*, erro médio entre PICP e PINC (ACE) e *PI normalized average width* (PIANW).

### 3.2.1.7 Modelos Híbridos para a Previsão do Recurso Solar

Um modelo de previsão denominado *Variational Bayesian Convolutional Gate Recurrent Unit* (VB-ConvGRU) é proposto em Liu *et al.* (2019a), com o objetivo de prever a irradiação solar no espaço e no tempo (horizonte horário), utilizando Deep Learning (DL) e combinando as vantagens de GRU e CNN. O modelo VB-ConvGRU-VB supera os outros quatro modelos competitivos (DNN, RNN, LSTM e GRU) em todos os meses. Ghimire *et al.* (2019) propõem um modelo híbrido combinando *Convolutional Neural Network* (CNN) com a rede LSTM para reconhecimento de padrões para irradiação solar global. O modelo híbrido

proposto apresenta um desempenho superior aos métodos utilizados para comparação, obtendo um nRMSE de 1,515%.

Um algoritmo operacional de previsão solar para mercado em tempo real (MTR) é encontrado em Yang, Wu e Kleissl (2019). Os autores combinam NAM (previsões horárias), *pattern-matching algorithm* (PMA) (previsões de minutos) e NWP para prever de forma probabilística e determinística, visando apoiar o *independent system operator* (ISO), da Califórnia. Um modelo híbrido combinando NWP e um modelo estocástico para prever IND, com o objetivo de criar um modelo para entender toda a dinâmica de alta frequência do IND, é desenvolvido em Peruchena *et al.* (2017). A série IND é realizada para o horizonte de previsão horária usando interpolação linear (IL) e caminhos dinâmicos (CD).

Um método híbrido é implementado em de la Rosa, Nuñez e Roca (2019) para prever a irradiação solar para gerar dados que possam contribuir para o projeto e teste de sistemas FV antes da instalação. A metodologia é baseada no cálculo de parâmetros de normalização, tendências médias e distribuições de probabilidade, que podem ser aplicadas para horizontes de curto e longo prazo.

Uma abordagem híbrida que combina *Principal Component Analysis* (PCA), Transformada *Wavelet* (WT) e RNA para a previsão de mapas diários de irradiação solar de superfície é proposta em Li *et al.* (2020). O PCA reduz a dimensionalidade dos dados. A WT é aplicada aos primeiros 28 componentes principais (CP), usados como entrada para a RNA para realizar a previsão.

Uma abordagem híbrida automatizada é proposta em Raghavan e Gopalan (2018), combinando WRF com calculadora solar (desenvolvida na caixa *numerical toolbox OpenFOAM*), além de um algoritmo para extração de contorno. WRF é usado para um cálculo inicial de irradiação no local desejado; em seguida, a radiação solar direta e difusa do WRF é usada para acionar uma calculadora solar. Uma técnica de combinação é aplicada em Verbois *et al.* (2018) com base na combinação de última geração de WRF com técnicas de aprendizado estatístico multivariado para fornecer as informações mais precisas para a previsão de irradiância horária do dia seguinte em Cingapura.

Os impactos dos microclimas nos erros de previsão solar são avaliados em Pedro e Coimbra (2015) por meio de previsões globais de irradiação solar. As previsões são baseadas na otimização de kNN e RNA. Os parâmetros ótimos para os modelos kNN e RNA são dependentes do microclima e nebulosidade. Uma seleção de recursos é necessária para aumentar a precisão dos métodos; AG têm potencial para este fim.

Um modelo híbrido é encontrado em Dong *et al.* (2015) combinando SOM, SVR e PSO para previsão horária de irradiância solar no Colorado, EUA e Cingapura. O modelo híbrido é comparado com os modelos ARIMA, *linear exponential smoothing* (LES) e *Single Exponential Smoothing* (SES); o modelo proposto mostra 4% menos erro do que a melhor precisão de previsão de todos os modelos comparados. Uma combinação de abordagens de estimativa de densidade do *kernel* e modelos de previsão de volatilidade para prever IHG é encontrada em Trapero (2016). A distribuição do erro é assumida como normal (hipótese paramétrica), e sua variância tem propriedades variantes no tempo estimadas pelos modelos *Generalized Autoregressive Conditional Heteroskedastic* (GARCH) e SES.

Dois métodos para estimar a altura da base da nuvem (ABN) usando um único gerador de imagens do céu e medições distribuídas de irradiância solar são propostos em Wang, Urquhart e Kleissl (2019d). Os métodos são: Correlação de Séries Temporais (CST) e *Geometric Cloud Shadow Edge* (GCSE). O ABN é importante para previsões solares e pode causar previsões incorretas de sombras e, posteriormente, erros de previsão de energia.

Uma metodologia combinando SES com métodos heurísticos de decomposição de séries temporais para prever IHG é proposta em Yang *et al.* (2015). Três estratégias diferentes são testadas: a) decomposição da tendência sazonal; b) decomposição do IHG (componente direto e difuso); e c) consideração do índice de cobertura de nuvens. Um método de correlação espacial e temporal para melhorar o desempenho da previsão da geração solar em sete locais na Califórnia é proposto em Zagouras, Pedro e Coimbra (2015). Regiões microclimáticas marítimas, mediterrâneas, áridas e semiáridas são consideradas nessa aplicação.

Um sistema híbrido de previsão combinando a TP e diferentes técnicas de IC é proposto em Lima *et al.* (2020). Considerando os dados da Espanha, as previsões usando DL têm um MAPE de 6,89% e usando a PrevTP um MAPE de 5,36%. Para dados do Brasil, a previsão obtém MAPE de 6,08% e 4,52% para DL e PrevTP, respectivamente.

Os benefícios da previsão solar como ferramenta para auxiliar no equilíbrio entre demanda e oferta são apresentados em Kaur *et al.* (2016). Em horizontes de previsão de 24 h e 5 min são comparados os seguintes modelos: a) SVR com seus parâmetros otimizados por um AG; b) modelo de persistência; e c) persistência inteligente (SP). Uma metodologia baseada no *Satellite Application Facility on Climate Monitoring* e modelo McClear (SAF CM) é usada em Aguiar *et al.* (2019) para analisar e comparar com 22 estações de medição de solo nas Ilhas Canárias. Diferentes situações são testadas: céu claro ou nublado e estação do ano.

Um modelo híbrido é proposto em Hocaoglu e Serttas (2017) para prever a irradiação solar, usando o algoritmo determinístico de *Mycielski-Markov*. O algoritmo *Mycielski* é testado em Antalya e Afyonkarahisar, Turquia. O modelo proposto apresenta os melhores resultados na localidade de Antalya (menor nebulosidade e dias mais claros). Um modelo híbrido usando dados de diferentes estações meteorológicas na Coreia do Sul é proposto em Nam e Hur (2019) para prever o recurso solar. Os métodos são NBC e técnica de modelagem espacial; o modelo de previsão apresenta um *Relative Mean Bias Error* (rMBE) de 15%.

*Multivariate Empirical Mode Decomposition* (MEMD), *singular value decomposition* (SVD) e RF são combinados em Prasad *et al.* (2020) para prever a irradiação solar através da não linearidade e não estacionaridade de deficiências que ocorrem naturalmente em preditores climatológicos. Método de IC com *ant colony optimization* (ACO), MEMD e RF são combinados em Prasad *et al.* (2019). O modelo aplicado na Austrália obtém o maior coeficiente de correlação (R) e o menor RMSE e MAE (R = 0,984, RMSE = 0,89 MJ/m<sup>2</sup>, MAE = 0,69 MJ/m<sup>2</sup>). Um modelo de AM para predição de IHG é proposto em Bouzgou e Gueymard (2019), combinando *Mutual Information Measure* (MIM) com ELM. Os testes são realizados usando séries de irradiância solar para duas regiões áridas (Madina - Arábia Saudita e Tamanrasset - Argélia) com diferentes horizontes de previsão (5 e 60 minutos).

Uma abordagem híbrida usando EMD, EEMD e decomposição *Wavelet* (WD) é proposta em Monjoly *et al.* (2017). Os modelos são comparados com modelos AR e não lineares. Um modelo híbrido utilizando um modelo de previsão IND (algoritmo *Heliosat2*) baseado em imagens de satélite, aplicando um fator de atenuação determinado pela presença de nuvens, é proposto em Alonso-Montesinos *et al.* (2019a); duas câmeras digitais e o modelo *Fiat-Lux* para prever IND em escala intra-hora também são usados. Também é determinado o pico de irradiância solar no receptor da usina *CESA-I Concentrating Solar Power* (CSP), Almería.

A técnica *Weighted Gaussian Process Regression* (WGPR) é aplicada em Guermoui, Melgani e Danilo (2018) para prever a IHG e IND no clima do Saara, Argélia no horizonte de previsão diária. Duas arquiteturas WGPR são propostas: *WGPR Parallel Forecasting Architecture* (WGPR-PFA) e *WGPR Cascade Forecasting Architecture* (WGPR-CFA).

Uma combinação de uma LSTM e codificador de dados de séries temporais em imagens usando o *Gramian Angular Field* (GAF) é proposta em Hong, Martinez e Fajardo (2020) para prever a irradiação solar diária. Um conjunto de dados IHG de Taiwan é usado e o modelo é testado usando o teste de classificação sinalizada de *Wilcoxon*. O método é comparado com ARIMA, CNN-LSTM e LSTM com rede *fully connected* (FC).



Um modelo de previsão é implementado em Maleki, Khajeh e Rosen (2016) com dados de uma planta de osmose reversa que fornece água potável para uma área remota no nordeste do Irã. O modelo proposto é baseado em RNA e *harmony search* (HS). Uma RNA é utilizada em Raffán, Romero e Martinez (2018) para a elaboração de uma curva de irradiação solar ideal, combinando métodos de aprendizado estatístico e NWP. Os dados vêm de San Juan - Argentina e são filtrados para condições climáticas extremas. Ensaios de vento de características *Zonda*, norte ou sul, são realizados: O vento *Zonda* é o fenômeno com maior impacto na redução da irradiação solar.

Combinações de diferentes métodos são propostas em Boland, David e Lauret (2016) para prever a irradiação solar em regiões na costa (Adelaide - Austrália), no interior (Las Vegas - EUA) e em ilhas (St. Pierre - Ilha da Reunião; Oahu - Havaí; e Fouillole - Guadalupe). Duas abordagens são propostas: 1) um método empregando séries de *Fourier* e modelos autorregressivos - *classical time series* (CTS); 2) um modelo de índice de céu claro combinando ANN e ARMA.

O impacto das previsões do IND na produção de uma usina CSP é analisado em Alonso-Montesinos *et al.*, (2019b). O método de previsão é o *System Advisor Model* (SAM), um modelo técnico-econômico gratuito. Gemasolar, Espanha e Crescent Dunes, Nevada são as plantas analisadas.

O uso de modelos baseados em DL para comparação com diferentes metodologias de previsão, com diferentes atrasos no vetor de entrada, é encontrado em Wang, Qi e Liu (2019a). O modelo de RNA desenvolvido com a ferramenta de ajuste tem o melhor efeito preditivo de irradiação solar com o maior número na entrada. Um modelo híbrido baseado em uma combinação de RNA estrutural autorregressiva e não linear, onde a entrada estrutural é o número do mês atual, é proposto em Ozoegwu (2019); o objetivo é melhorar a precisão dos métodos de previsão autorregressiva não linear e simplificar a camada de entrada do método autorregressivo não linear (exógeno).

Um modelo de previsão de velocidade do vento e irradiação solar em microrredes visando contribuir para a gestão de energia é analisado em Heydari *et al.* (2019). O modelo híbrido utilizado combina RNA, *Group Method of Data Handling* (GMDH) e *Modified Fruit Fly Optimization* (MFOA).

Uma combinação de Transformada Discreta de Fourier (TDF) com PCA e RNA *Elman* para a previsão espaço-temporal da irradiação solar é desenvolvida em Lan *et al.* (2019). O método é aplicado para diferentes estações do ano, obtendo-se os melhores desempenhos para

verão e inverno. Um método de previsão de IHG é proposto em del Campo-Avila *et al.* (2019) visando a avaliação de desempenho nas faixas de resposta espectral de módulos FV de filme fino. Diferentes algoritmos de classificação são testados (diferentes configurações).

KF e preditores regressores são combinados em Cheng (2016) para prever a irradiância solar, com o objetivo de se beneficiar das vantagens de ambas as técnicas. Uma modelagem híbrida utilizando uma estrutura hierárquica *bayesiana* em conjunto com o KF estendido para realizar a regularização no aprendizado sequencial de uma RNA para modelagem de irradiação solar é encontrada em Hussain e AlAlili (2016). A proposta é comparada com NARX e *linear regression multivariate* (MLR). Os métodos são aplicados com e sem *outliers*, que introduzem componentes de alta frequência ou transientes no sinal.

O uso dos métodos WRF e RNA para prever a irradiação solar no Nordeste do Brasil é analisado em Lima *et al.* (2016); a divisão da região em quatro áreas é baseada em características meteorológicas semelhantes. As RNA apresentam melhores resultados, gerando menos viés e RMSE e aumento de R para todas as aplicações nas áreas, no período seco e chuvoso.

O uso combinado de SVM e *Least Squares* (LS-SVM) e algoritmo de *artificial bee colony* (ABC) é encontrado em Guermoui *et al.* (2020) para prever a radiação solar global. ABC é usado para otimização de parâmetros, clássico (LS-SVM) e Cuckoo Search Least Squares - Support Vector Machine (CS-LS-SVM) são usados como modelos de referência para comprovar o desempenho do modelo híbrido.

Diferentes combinações híbridas de modelos estatísticos baseados em diferentes tipos de algoritmos de RNA, usando medições *in situ* e modelos *output statistics* (MOS) (usando dados NWP e medições locais, como entrada de RNA e modelo de persistência) são analisadas em Cornaro *et al.* (2015). Uma combinação de LSTM e uma função baseada em *integral Choquet* é usada em Abdel-Nasser, Mahmoud e Lehtonen (2021) para prever a irradiância solar. O modelo é *reliable deep forecasting model* (RDFM) e usa blocos LSTM. Por meio de uma medida difusa, a *integral Choquet* modela a interação entre as entradas a serem agregadas.

### 3.2.1.8. Modelos Híbridos para a Previsão da Geração FV

Um método de previsão em tempo real para uma usina FV de 48 MWp é proposto em Chu *et al.* (2015), usando RNA e AG. A metodologia visa melhorar o desempenho de três metodologias: um modelo físico baseado em rastreamento de nuvem, ARMA e kNN. A análise

é baseada na estatística de erros comuns, mostrando a redução do erro de viés médio, principalmente em períodos de alta variabilidade, redução da ocorrência de erros altos e melhora da capacidade de predição. SARIMA e rede neural do tipo *random vector functional link* (RVFL) são combinados em Kushwaha e Pindoriya (2019) para uma previsão de geração FV de curto prazo.

O BMA é proposto em Doubleday *et al.* (2021) para prever a potência FV em diferentes horizontes de tempo. O pós-processamento de BMA é executado para montagens NWP. Aplicada a 11 usinas FVs em escala de utilidade no Texas, a metodologia reduz a subdispersão do conjunto bruto e melhora a calibração de previsão.

Aplicações hibridizadas determinísticas (WRF) e estocásticas (vários modelos AM) para previsão solar são comparadas em Pierro *et al.* (2017). Modelos híbridos de previsão para alimentadores movidos a energia solar na Califórnia são propostos em Chu *et al.* (2017), baseados em RNA e SVR, ambos acoplados a métodos que processam imagens do céu. A introdução de imagens do céu aumenta a precisão do modelo em até 43%.

Uma abordagem corretiva usando erros de previsão solar é proposta em Wang *et al.* (2019c). Aplicada a edificações em San Bernardino, Califórnia, a proposta inclui a programação inteligente de Veículos Elétricos (VE), usando programação quadrática (PQ) para otimização e suporte da abordagem, um algoritmo *Receding horizon optimization* (RHC), para modificar a ação de controle em relação à geração FV esperada, e satisfazer as restrições em janela de tempo fixa (24 h).

Modelos de previsão de séries temporais sazonais para geração FV são aplicados em Yang e Dong (2018), usando SARIMA, ETS, MLP, *single task learning* (STL), TBATS (*Exponential Smoothing Method + Box-Cox Transformation + ARMA model for residuals + Trigonometric Seasonal*) e famílias teta. De cada família, seis modelos são selecionados usando o *Akaike information criterion* (AIC) e suas previsões são combinadas usando oito métodos.

As previsões da geração FV por meio de SVR, um NWP e um modelo de *cloud motion vector* (CMV) são comparadas em Wolff *et al.*, (2016). As previsões regionais são desenvolvidas com horizontes de previsão que variam de 15 minutos a 5 horas à frente; os dados são provenientes de 921 sistemas FV na Alemanha, de 2012 a 2013. Um sistema híbrido combinando *Differential Polynomial Neural Network* (D-PNN) e NWP para previsão de potência FV é aplicado em Zjavka (2020). A metodologia tem uma precisão de previsão melhor do que as soluções estatísticas simplificadas.

Um modelo de previsão de geração FV de curto prazo para um sistema *off-grid* é proposto em Jamal *et al.* (2019), usando uma ferramenta de modelagem de fluxo de energia e a integração da previsão do nível da geração FV e da bateria. A ferramenta oferece recursos apropriados para planejadores de sistemas ou partes interessadas que desejam compreender de forma abrangente a confiabilidade potencial da previsão FV de curto prazo, juntamente com economia de diesel e outros benefícios potenciais.

Um modelo híbrido combinando RNA com *wavelet* para prever a potência FV é usado em Chaudhary e Rizwan (2018). O armazenamento hidráulico bombeado é usado para atender aos requisitos da rede e resposta à demanda (RD). Além da previsão, é realizado um sistema de gestão com plataforma *MATLAB/Simulink* e validado em um sistema FV de 5 kW. Uma abordagem de previsão com o objetivo de melhorar o desempenho de módulos FV que apresentam comportamento semelhante é analisada no estudo de Shireen *et al.* (2018). Um algoritmo de séries temporais de processo gaussiano de aprendizado multitarefa é desenvolvido para aprender as observações ausentes no conjunto de dados sem aumentar os esforços de medição.

Uma previsão híbrida visando contribuir para o gerenciamento de uma microrrede multiagente é proposta em Afrasiabi *et al.*, (2019). Um modelo que combina CNN com *gated recurrent unit* (GRU) é usado para energia eólica e solar, demanda e preços de mercado. O modelo CNN-GRU é comparado com ARIMA, NNE, kNN, LSTM, GRU, CNN e CNN-LSTM. *Deep Learning* LSTM e CNN são combinados em Wang, Qi e Liu (2019b) para prever a potência FV em um modelo híbrido. O desempenho do modelo híbrido proposto é comparado com a aplicação dos modelos combinados individualmente e com um modelo híbrido LSTM-CNN de outra aplicação.

*Improved chicken swarm optimization* (ICSO), *chicken swarm optimization* (CSO) e o ELM são combinados em Liu *et al.* (2020b) para prever a geração FV sob condições nubladas, ensolaradas e chuvosas. O modelo proposto é comparado com os modelos CSO-ELM, SVM, BP e GPR, apresentando o menor RMSE em todas as condições meteorológicas. Modelos de algoritmos de agrupamento PCA e *K-means* com algoritmo de RF otimizado pelo *Differential Evolution Gray Wolf Optimizer* (HGWO) são combinados em Liu e Sun (2019) para prever a potência FV em três regiões. As combinações são comparadas com SVM, RNA, árvore de decisão e modelo de regressão gaussiana.

Um modelo híbrido adaptativo *predictor subset selection* (PSS) é proposto em Eseye *et al.* (2019). Um algoritmo genético binário (AGB) é usado para seleção de recursos e SVR é

usado para medir o núcleo do preditor. Dois modelos de previsão de geração FV são comparados em Dawan *et al.* (2020): o primeiro modelo usa ANFIS; o segundo modelo utiliza o modelo PSO da IC combinada com métodos de RNA (PSO-RNA).

Diferentes combinações baseadas em CNN com um algoritmo de janela deslizante são encontradas em Suresh *et al.* (2020). São aplicados CNN comum, CNN *multi-headed* e CNN-LSTM, e os testes são comparados com os modelos de média móvel autorregressiva e de regressão linear múltipla. LSTM e um algoritmo PSO são usados em Zheng *et al.* (2020) para a previsão da geração FV no horizonte de longo prazo. O PSO é usado para otimizar os parâmetros do modelo de previsão (unidades neurais, taxa de aprendizado, intervalo de tempo e tamanho do lote). Diferentes estruturas LSTM são comparadas para determinar a previsão final.

Uma metodologia para prever a produção de eletricidade com base em imagens do céu e o uso de RNA para horizontes de até 15 min com resolução de 1 s é proposta em Anagnostos *et al.* (2019). Em um *predictive energy management system* (PEMS) em um edifício em Berlim, uma metodologia híbrida para previsão diária de geração FV, por meio da combinação de RNA e modelo físico, é proposta em Schmelas *et al.* (2015). RNA-MLP aplicado individualmente, MLP com e sem informação física são testados e comparados. Na Tabela 3.1 são apresentados os artigos mais citados de acordo com a presente revisão de literatura, considerando cada uma das abordagens de previsão (fenomenológica, estatística, AM e modelos híbridos). O número de citações é obtido por meio do google acadêmico.

Tabela 3.1 - Resumo das metodologias de previsão solar mais citadas

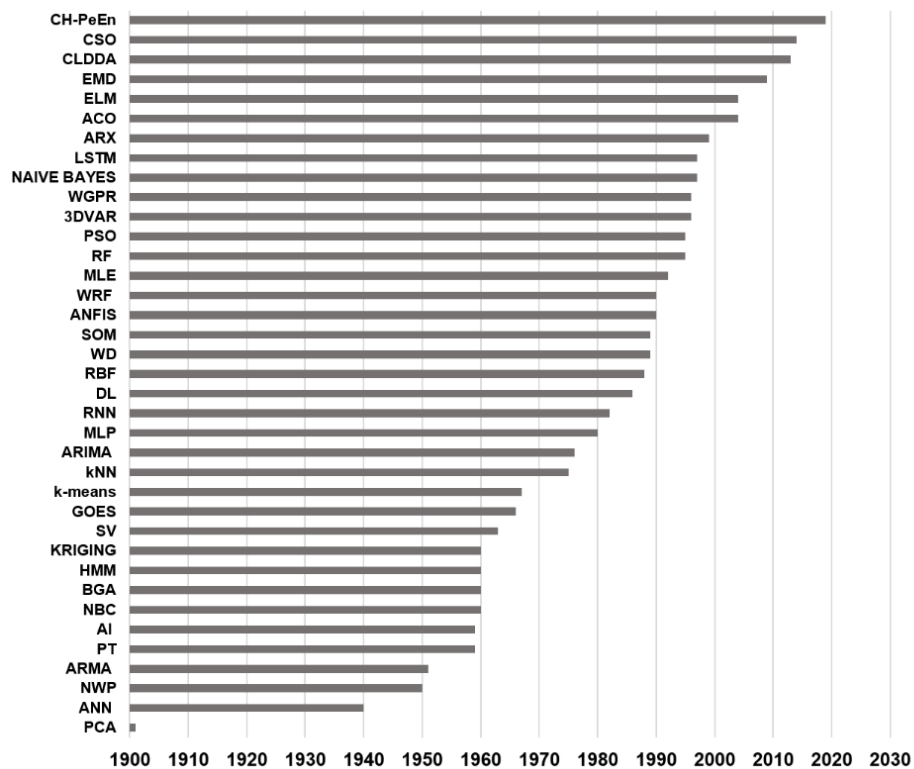
<b>Referências</b>	<b>Método de Previsão</b>	<b>Horizonte de Previsão</b>	<b>Meta de Previsão</b>	<b>Escala Espacial de Previsão</b>	<b>Citações (<i>google scholar</i>)</b>
(Qing; Niu, 2018)	LSTM	horário	Irradiação solar	campo único	290
(Huva; Verbois; Walsh, 2020)	NWP	horário	Geração FV	regional	161
(Yang, 2020)	Lasso	minutos	Irradiação solar	regional	92
(la Rosa <i>et al.</i> , 2019)	RNA e AG	horário	Geração FV	campo único	154

Fonte: Próprio autor.

### 3.2.2 Classificação dos artigos de revisão analisados e cronologia das técnicas aplicadas

Na Figura 3.6 são mostrados o ano de surgimento das principais metodologias encontradas na presente revisão, aplicáveis ao pré-processamento de dados, assimilação de dados, otimização de parâmetros e previsão de geração FV e irradiação solar. As principais técnicas foram propostas entre as décadas de 1940 e 2000.

Figura 3.6 - Ano de surgimento das principais metodologias de previsão



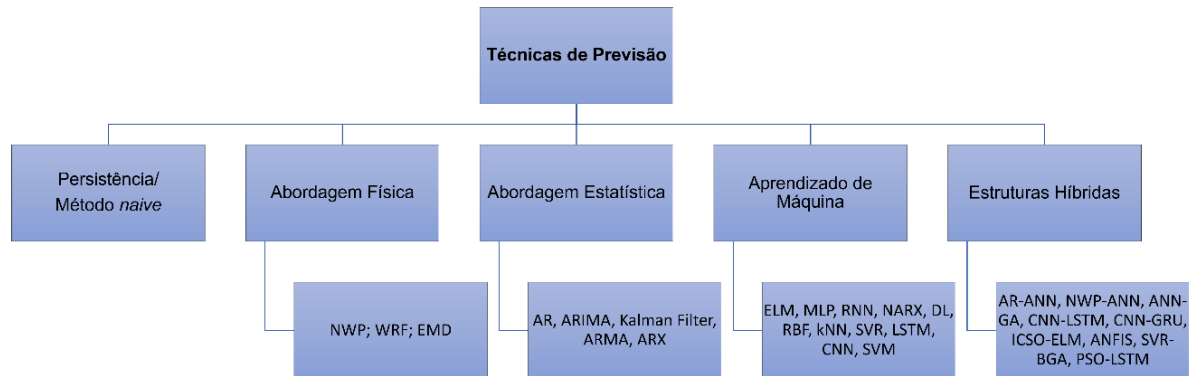
Fonte: Próprio autor.

As metodologias de previsão solar são classificadas de acordo com: a) abordagem (modelos físicos, estatísticos, híbridos, de persistência e AM); b) horizonte de previsão (curto, médio e longo prazo); c) previsão direta ou indireta (direta: a previsão da geração FV é realizada; indireta: a geração FV é estimada após a previsão do recurso solar); e d) escala de previsão espacial (previsão de campo único ou regional).

Na Figura 3.7 são apresentadas as metodologias dos artigos revisados de acordo com a abordagem. A tendência dos modelos híbridos é significativa e a maioria dos modelos combina

AM com outras técnicas mais tradicionais. Metodologias derivadas da IC, como PSO e ACO, têm sido amplamente utilizadas na otimização de parâmetros em metodologias de previsão solar.


Figura 3.7 - Classificação dos métodos de previsão da geração FV e do recurso solar



Fonte: Próprio autor.

Na Figura 3.8 é apresentada a porcentagem de artigos que aplicam as diferentes abordagens; o uso de AM e modelos híbridos representa mais de 70% do total de artigos que compõem a revisão. Métodos físicos são amplamente utilizados em modelos híbridos e quando os modelos são usados para otimização de parâmetros e pré-processamento, os modelos de AM são frequentemente utilizados. Uma tendência observada são os modelos que são aplicados com o objetivo de reduzir os erros de previsão (modelos de assimilação e modelos como a Previsão baseada na Teoria do Portfólio (PrevTP)).


Figura 3.8 - Classificação de acordo com a abordagem de previsão



Fonte: Próprio autor.

Na Figura 3.9 é mostrada a classificação das aplicações de acordo com o horizonte de previsão: curto, médio e longo prazo. A previsão de curto prazo é importante para a integração de sistemas FV e pode contribuir para a programação e despacho de energia elétrica. A previsão de médio prazo se destaca no planejamento e manutenção dos sistemas de energia. A previsão de longo prazo é importante no planejamento de geração, transmissão e distribuição de eletricidade (Kumar Das *et al.*, 2018). Destacam-se os horizontes de previsão horária e minuto, refletindo a alta participação da previsão de curto prazo (83%).

Figura 3.9 – Classificação de acordo com o horizonte de previsão

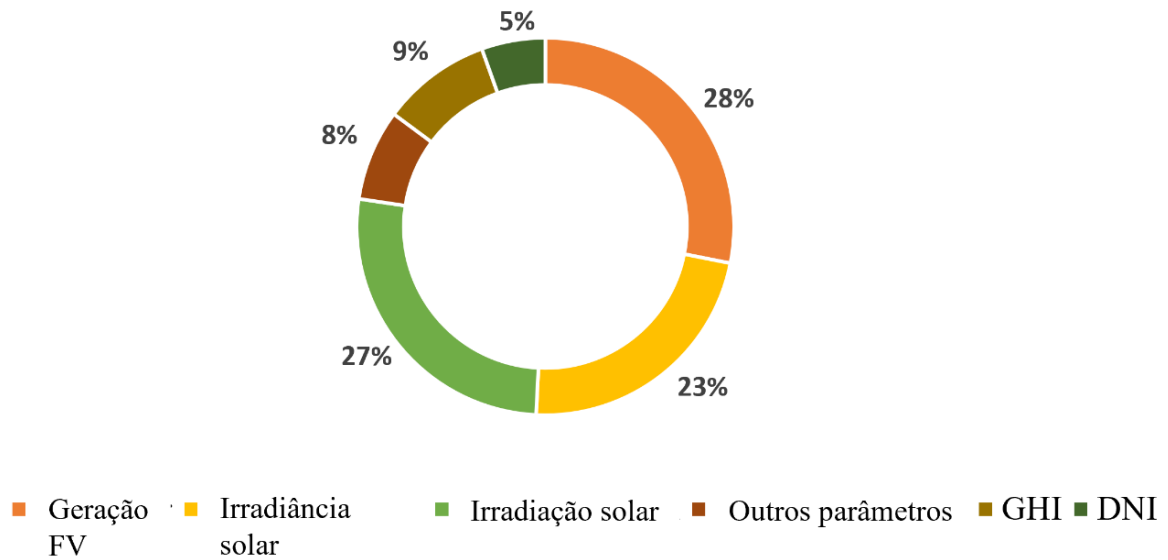


Fonte: Próprio autor.

Na Figura 3.10 são apresentados os objetivos de previsão nas diferentes aplicações. Algumas metodologias aplicam suas metodologias para prever diretamente a potência FV; em outros estudos, o recurso solar é previsto anteriormente, e outra metodologia é aplicada na sequência para estimar a potência FV. Aproximadamente 28% das aplicações são classificadas como diretas, fornecendo a geração FV. Uma parcela de 64% usa previsão indireta, usando irradiação solar ( $\text{Wh/m}^2$ ) e irradiância solar ( $\text{W/m}^2$ ), IHG ou IND como meta de previsão. 8% das aplicações, além de prever a potência FV ou realizar a previsão indireta, predizem outros parâmetros como a velocidade do vento, temperatura dos módulos FV, rampas, consumo de energia e  $S_c$ .



Figura 3.10– Classificação de acordo com a meta de previsão




Fonte: Próprio autor.

Na Tabela 3.2 são apresentados exemplos de técnicas aplicadas satisfatoriamente nos horizontes de curto, médio e longo prazos e suas limitações. O critério para escolha dos artigos é a frequência da metodologia encontrada em cada horizonte de previsão e o número de citações na literatura, obtidas por meio do *scholar google*.

Na Figura 3.11 são resumidos os dados referentes à classificação da escala espacial de previsão, destacando que as previsões de campo único representam mais de 65% do total.

Figura 3.11 – Classificação com base na escala espacial de previsão



Fonte: Próprio autor.

Tabela 3.2 - Técnicas relevantes aplicadas aos horizontes de curto, médio e longo prazo e suas limitações

Horizonte de Previsão	Técnicas	Referências mais citadas	Limitações
Curto prazo	kNN e kNNEn	(Chu e Coimbra, 2017) (Pedro; Coimbra, 2015a) (Wang; Urquhart; Kleissl, 2019d)	Funciona mal sob mudanças climáticas repentinas, precisando de um banco de dados extenso e completo.
	RF	(Aguiar <i>et al.</i> , 2016)	Para a previsão de IHG, IND e IHD, precisa ser combinada com algoritmos de otimização, a fim de funcionar corretamente.
	LSTM	(Qing; Niu, 2018)	Se combinado com NWP, tem um desempenho ruim no inverno.
	MLP	(Rahmann; Mayol; Haas, 2018)	Na previsão de potência FV, tem baixa precisão quando aplicado em locais com ocorrência de neve, com cobertura total ou parcial dos módulos.
Curto e médio prazo	NARX	(Boilley <i>et al.</i> , 2016)	Na presença de outliers, tem um desempenho pior do que os modelos híbridos.
	ACO, MEMD e RF	(Alonso-Montesinos <i>et al.</i> , 2019b)	Precisa de testes adicionais com horizontes de previsão inferiores a um mês, para fornecer maior compreensão em aplicações em tempo real.
Longo prazo	PSO-LSTM	(Yang; Dong, 2018)	Diferentes divisões de conjuntos de dados podem afetar o treinamento do modelo.
	Híbrido RNA	(Jamal <i>et al.</i> , 2019)	É limitado a aplicações de longo prazo.

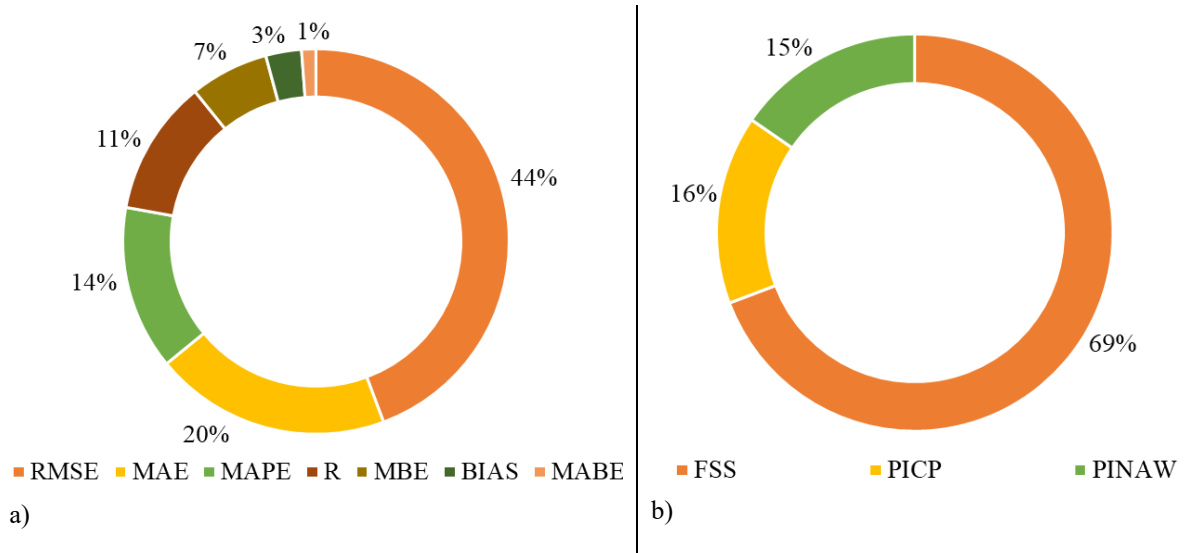
Fonte: Próprio autor.

### 3.2.3 Métricas de Avaliação de Desempenho

Outras análises relevantes comentam as métricas utilizadas para analisar a precisão das aplicações e as principais limitações e vantagens de cada aplicação. Medidas de desempenho padronizadas são amplamente utilizadas para avaliar o desempenho e comparar diferentes aplicações: RMSE, MAE, MAPE, R, FSS e MSE são aplicados com frequência, principalmente

a combinação de RMSE, MAE e MAPE. Na Figura 3.12 são apresentadas as métricas de erro mais utilizadas para avaliar a acurácia dos métodos que compõem esta revisão.

Figura 3.12 – Métricas de erro para avaliar a precisão dos métodos: a) determinísticas e b) probabilísticas



Fonte: Próprio autor.

As medidas de desempenho mais aplicadas nos artigos que compõem a revisão são RMSE, MAE, MAPE e R com 41,11%, 18,30%, 12,77% e 10,55%, respectivamente. É importante destacar que as medidas de desempenho devem ser aplicadas em conjunto para realizar uma avaliação global das metodologias. Parâmetros probabilísticos, como PINAW, PICP e FSS, também podem ser aplicados para avaliação de metodologias de previsão, mas são encontrados em menor quantidade.

### 3.2.4 Discussão: Análise Global

Por meio desta *qSLR*, foram identificados 140 artigos relevantes para responder às perguntas de pesquisa relacionadas à previsão solar. Com base nos dados extraídos desses artigos, foram reunidas algumas evidências sobre o assunto.

1. Dependendo do local, condições ambientais, disponibilidade e tipo de dados, qualquer uma das abordagens pode funcionar bem (Wolpert; Macready, 1997);
2. Os métodos baseados em AM apresentam resultados positivos na previsão solar, mas precisam de um banco de dados histórico suficientemente grande e de qualidade para

treinamento, capacidade de preparação de dados, software específico e, muitas vezes, alto custo computacional para processamento dos algoritmos;

3. Os métodos de AM costumam usar fundamentos estatísticos para obter a precisão de suas aplicações, mas os motivos não são explicados;

4. Uma vantagem da abordagem estatística é poder explicar as razões relacionadas às previsões, mas a maioria delas são menos precisas que os métodos de AM;

5. Quando há necessidade de interpretação e precisão, os modelos combinados aparecem para obter o melhor de cada metodologia e bons resultados, em comparação aos modelos individualizados;

6. Os modelos baseados em NWP são tão complexos quanto o entendimento dos processos atmosféricos e dos fluxos de irradiância em múltiplos níveis, apresentando essa dificuldade de entendimento atmosférico como uma de suas limitações. Aplicações como essas necessitam de informações de imagens de satélites, o que exige alto processamento computacional, gerando resultados que demonstrem a incidência de irradiação solar na superfície analisada;

7. O principal aspecto a ser analisado nas aplicações de previsão solar é a intermitência do recurso solar, visando um planejamento confiável da geração de energia elétrica. Assim, a mitigação da variabilidade da potência FV está ligada ao estudo da variação da irradiação solar incidente na superfície do módulo, causada por atenuações atmosféricas. Tais impactos podem ser minimizados utilizando recursos intermitentes em locais com diferentes características ambientais;

8. As principais limitações das previsões solares estão ligadas ao equilíbrio entre oferta e demanda, por meio da gestão de outras fontes para complementar a geração FV em momentos adversos. O mapeamento confiável de dados e recursos tem sido um ramo de pesquisa na área de previsão solar cada vez mais necessário para melhorar o desempenho de usinas FVs em todo o mundo;

9. As principais tendências são a utilização de modelos híbridos, combinando técnicas que podem auxiliar na otimização dos parâmetros do modelo e na redução de aspectos como custo computacional e tempo de treinamento;

10. Uma área de estudo relevante é a precisão dos modelos, mas também a criação de modelos flexíveis capazes de gerir toda a informação em simultâneo, na ausência de dados;
11. São necessários modelos classificados como regionais, aplicáveis a diferentes condições climáticas e diferentes horizontes de previsão. Diferentes horizontes são importantes para auxiliar na tomada de decisão, considerando, em curto prazo, manutenção, programação e despacho de energia elétrica, e em longo prazo, geração, transmissão e distribuição;
12. Diferentes técnicas podem ser combinadas; RNA e diferentes métodos estatísticos combinados apresentam bom desempenho em diferentes aplicações;
13. Os modelos *ensemble* podem melhorar significativamente a precisão em termos de minimização dos erros de previsão, em comparação com os preditores individuais, mas os seguintes pontos devem ser considerados: a maior parte dos trabalhos relacionados calculam as médias ponderadas ou valores médios entre as previsões de modelos individuais; devem ser consideradas as interações entre os valores a serem agregados.

As principais limitações da maioria das aplicações são: a) alto custo computacional; b) necessidade de grandes quantidades de dados; c) sensibilidade a diferentes condições climáticas; d) necessidade de imagens de satélite; e) especificidade na aplicação; f) alguns modelos híbridos apresentam desempenho inferior em relação a diferentes modelos aplicados individualmente; g) tempo de treinamento prolongado; e h) algumas aplicações são de difícil compreensão.

A otimização de parâmetros também tem mostrado bons resultados em aplicações híbridas, com a maioria das aplicações utilizando metodologias de IA. Alguns métodos buscam reduzir a dimensionalidade dos dados de entrada sem perder o desempenho das previsões. Vários métodos são testados em diferentes regiões, para diferentes condições climáticas (condições ideais e não ideais) e em diferentes horizontes de previsão.

### ***3.2.5 Discussão: Análise por Técnica***

Considerando as técnicas aplicadas individualmente ou em modelos híbridos, alguns pontos devem ser considerados:

A NBC pode ser aplicada individualmente ou em modelos híbridos, com dados de diferentes estações (Yang, 2019; Nam; Hur, 2019). Usando dados regionais e obtendo boa

precisão, NARX, na presença de *outliers*, foi inferior aos modelos híbridos (Hussain; Alalili, 2016). As metodologias kNNEn e kNN têm sido frequentemente aplicadas à previsão solar nos últimos anos (Chu; Coimbra, 2017; Fouilloy *et al.*, 2018; Pedro; Coimbra, 2015a; Pedro *et al.*, 2018b; Pedro; Coimbra, 2015). Com um FSS de 14,9 %, um bom desempenho para preditores IND, o kNN pode ter limitações na previsão de irradiância solar quando o clima muda repentinamente, e requer, em algumas aplicações (Pedro; Coimbra, 2015a), um banco de dados grande e completo; IPs podem melhorar as previsões.

Comparado a outros modelos de RNA, o RF apresentou bom desempenho e aplicabilidade na previsão de IHG, IND e IHD, em diferentes horizontes de previsão; seu desempenho pode ser melhorado quando aplicado em combinação com algoritmos de otimização (Benali *et al.*, 2019; Liu; Sun, 2019). Modelos SVM têm sido aplicados para previsão solar com bom desempenho, tanto individualmente (Li *et al.*, 2016), em diferentes condições climáticas, quanto combinados com suporte ABC e Mínimos Quadrados, onde os parâmetros são otimizados (Guermoui *et al.*, 2020).

O LSTM mostrou um bom potencial para previsão solar e tem sido amplamente aplicado nos últimos anos; combinado com previsões de NWP e fatores sazonais (Liu; Sun, 2019), teve melhor desempenho na primavera e desempenho inferior no inverno. Na previsão diária de irradiação solar (Qing; Niu, 2018), o LSTM foi quase 9% mais preciso que o RRNM. Aplicável quando é necessária flexibilidade para previsões na ausência de sensores, o LSTM tem sido amplamente aplicado em modelos híbridos, combinado com GAF, em previsões IHG (Hong; Martinez; Fajardo, 2020), PSO (Zheng *et al.*, 2020), para otimizar os parâmetros do modelo, e CNN, mostrando superioridade (Suresh *et al.*, 2020) a vários modelos usados para comparação; LSTM, combinado com RDFM em estratégias de agregação (Abdel-Nasser; Mahmoud; Lehtonen, 2021), foi superior a vários modelos aplicados individualmente (ARIMA, persistência).

A MLP, usada há anos para prever diferentes tipos de séries temporais, também tem sido frequentemente usada na previsão solar (Mccandless; Haupt; Young, 2016; Ali Jallal *et al.*, 2020), principalmente em aplicações no horizonte horário. Usando imagens derivadas de satélite, as redes MLP funcionam bem sob céu claro. Aplicado isoladamente ou em modelagem híbrida com modelos físicos (Abdel-Nasser; Mahmoud; Lehtonen, 2021), o MLP apresentou limitações nos resultados que podem ter sido causadas pela época do ano, quando a neve cobre os módulos.

As RNA RBF têm sido testadas nas mais diversas aplicações em previsão solar, sendo superiores ao AR em Hu *et al.* (2018) e com desempenho inferior a algumas aplicações híbridas, como EEMD-SOM-BP (Lan *et al.*, 2018). A CNN tem sido utilizada em muitas aplicações, com modelagem híbrida como CNN-LSTM, atingindo um nRMSE de 1,515% (Ghimire *et al.*, 2019; Wang, Qi; Liu, 2019b). A combinação de GRU e CNN (Liu *et al.*, 2019b; Suresh *et al.*, 2020) foi superior a vários modelos, incluindo CNN-LSTM.

ANFIS são usados para previsão solar para estimar o potencial solar de locais (Nirudh; Somchat, 2019), com um bom desempenho em comparação com RNA tradicionais e modelos híbridos (Dawan *et al.*, 2020). O AG pode ser aplicado a estudos de viabilidade em sistemas sustentáveis de fornecimento de energia (ALFULAYYIH; GWESHA, 2019), e como parte de modelos híbridos (la Rosa *et al.*, 2019; Kaur *et al.*, 2016), para otimizar os parâmetros e a seleção de variáveis. A lógica *Fuzzy*, já amplamente aplicada na ANFIS, também apresenta potencial de aplicação em sua forma tradicional (Sridharan *et al.*, 2018).

Considerando os modelos físicos, o WRF tem sido amplamente aplicado individualmente ou em modelos híbridos (Aryaputera; Yang; Walsh, 2015; Nonnenmacher; Kaur; Coimbra, 2016) e seu desempenho foi aprimorado ao utilizar pré-processadores (Yang; Kleissl, 2016); em comparação com modelos estocásticos (Pierro *et al.*, 2017), o WRF foi um pouco menos preciso. WRF mostrou potencial (Raghavan; Gopalan, 2018) como estimativa inicial de irradiação solar em áreas urbanas; combinado com ferramentas estocásticas, foi superior ao modelo de persistência (Verbois *et al.*, 2018; Lima *et al.*, 2016). GP foram usados em modelos dinâmicos (Van Der Meer *et al.*, 2018; Guermoui; Melgani; Danilo, 2018) e em algoritmos de séries temporais para prever observações faltantes (Shireen *et al.*, 2018).

Considerando modelos híbridos, as descobertas podem ser resumidas da seguinte forma:

1. Combinações de modelos determinísticos e estocásticos são encontradas em diversos trabalhos e tendem a aumentar a precisão das previsões (Yang; Wu; Kleissl, 2019; Peruchena *et al.*, 2017; Verbois *et al.*, 2018; Zjavka, 2020; Alonso-Montesinos *et al.*, 2019b; Anagnostos *et al.*, 2019);
2. RNA combinada com algoritmos, visando otimizar parâmetros e reduzir limitações inerentes ao microclima e nebulosidade, tem sido amplamente aplicada nos últimos anos (la Rosa *et al.*, 2019; Pedro; Coimbra, 2015; Zagouras; Pedro; Coimbra, 2015; Liu *et al.*, 2020; Eseye *et al.*,

2019; Dawan *et al.*, 2020; Zheng *et al.*, 2020; Wang, Qi; Liu, 2019a; Heydari *et al.*, 2019; Guermoui *et al.*, 2020);

3. O pós-processamento melhorou a precisão das previsões (Doubleday *et al.*, 2021);

4. Combinações de modelos estatísticos com RNA ou combinações de diferentes RNA com dois ou mais modelos estatísticos melhoram o desempenho de modelos híbridos (Chu *et al.*, 2017; Chaudhary; Rizwan, 2018; Suresh *et al.*, 2020; Cheng, 2016; Hussain; Alalili, 2016);

5. Combinações de previsões individualizadas, visando a redução de erros (Yang; Dong, 2018; Lima *et al.*, 2020), têm gerado resultados com maior precisão;

6. Algoritmos de decomposição, combinados com outros preditores, foram aplicados (Prasad *et al.*, 2020); e

7. Diferentes condições de céu foram aplicadas na avaliação dos modelos (Aguiar *et al.*, 2019).

### **3.3 Metodologias de Previsão Eólica**

A intermitência do recurso eólico faz que a produção elétrica seja um desafio aos sistemas e mercados de energia, fazendo das previsões do recurso e da geração ferramentas relevantes e necessárias para a operação ideal e comercialização desse tipo de energia (Yousuf; Al-Bahadly; Avci, 2019). Para Yaghoubirad *et al.* (2023), a previsão precisa do recurso eólico melhora o planejamento da geração elétrica e reduz os custos envolvidos.

As previsões podem ser determinísticas, probabilísticas e multivariadas ou previsões para eventos específicos, como rampas ou rajadas de vento (Messner *et al.*, 2020). Alguns trabalhos já calculam os benefícios que as previsões podem fornecer aos sistemas elétricos (Pierro *et al.*, 2022), como também no uso de modelos preditivos na modelagem de despacho ótimo para o dia seguinte do armazenamento eólico (Nguyen; Le, 2021).

De acordo com Zamo, Bel e Mestre (2021), a previsão eólica na superfície apresenta algumas limitações que devem ser consideradas e que estão associadas às interações complexas entre diferentes fenômenos: a) estruturas atmosféricas de grande escala; e b) orografia local. As flutuações súbitas dos ventos também configuram uma área de estudo relevante, especialmente, quando consideramos a elevada inserção da geração eólica no mundo. Essas flutuações são



chamadas de *wind power ramps (WPR)* e diversos trabalhos vêm prevendo esses eventos visando ajudar a gerenciar e despachar melhor a energia eólica (Cui *et al.*, 2019; Li *et al.*, 2020a).

Alguns trabalhos têm avaliado a capacidade dos sistemas globais de previsão climática sazonal. Autores como Lee *et al.* (2019) consideram que essas previsões podem fornecer mais informações climáticas úteis e confiáveis que podem ser usadas para a indústria de geração eólica.


Da mesma forma que na previsão solar, a previsão eólica requer dados históricos, confiáveis e disponíveis para sua implementação. Em Wilczak *et al.* (2019), são analisados dados coletados em diferentes conjuntos de instrumentos (torres altas, nas nacelles de aerogeradores, perfilhadores de vento e outros) e comparados os benefícios do uso de observações de sensoriamento remoto versus observações *in situ*. Os autores observam que, para horizontes de previsões mais longos, as observações *in situ* são menos relevantes, enquanto, o impacto das observações de sensoriamento remoto, permanece presente e relevante até a hora 15 da previsão. Ambos apresentam maior impacto na validação diurna e menor impacto na validação noturna.

Estudos como o Möhrle *et al.* (2022), investigam as barreiras existentes na indústria de energia para a adoção de previsões de incertezas em seus processos de decisão. Os resultados obtidos demonstram que os participantes apontam para uma indústria de energia que compreendeu a necessidade de previsão de incerteza no manuseio de fontes intermitentes. Mas, ressaltam que a adaptação das previsões de incerteza nas práticas do dia a dia das empresas ainda é um processo lento.

Por meio de pesquisas no Portal de Periódicos da Capes do Ministério da Educação, ScienceDirect, Scopus e no IEEE Xplore, com os seguintes filtros, foram elaborados os gráficos das Figuras 3.13 a 3.16. Os parâmetros de pesquisas foram: 1. Tipo de publicação: periódico; 2. Período de avaliação: janeiro de 2018 a março de 2023; 3. Tipo de periódico: revisado por pares; e 4. Área de pesquisa: previsão eólica.


Na Figura 3.13 são apresentados os autores da área de previsão eólica que se destacaram em número de publicações no período e a quantidade de seus trabalhos; na Figura 3.14 são apresentadas as coleções e a quantidade de artigos da área.

Figura 3.13 – Informações gerais a respeito de artigos sobre previsão eólica revisados por pares, publicados entre janeiro de 2018 e março de 2023: Autores



Fonte: Próprio autor.


Figura 3.14 – Informações gerais a respeito de artigos sobre previsão eólica revisados por pares, publicados entre janeiro de 2018 e março de 2023: Coleção



Fonte: Próprio autor.


Na Figura 3.15 são apresentados os principais periódicos e a quantidade de trabalhos na área; na Figura 3.16 são mostrados os continentes e o número de contribuições na área.

Figura 3.15 – Informações gerais a respeito de artigos sobre previsão eólica revisados por pares, publicados entre janeiro de 2018 e março de 2023: Jornal



Fonte: Próprio autor.

Figura 3.16 – Informações gerais a respeito de artigos sobre previsão eólica revisados por pares, publicados entre janeiro de 2018 e março de 2023: Continentes



Fonte: Próprio autor.

A coleção da *Wiley Online Library* apresenta o maior número de artigos da área (3.495 artigos publicados), seguida da coleção *Scopus (Elsevier)* (3.486 artigos publicados). Os periódicos que se destacaram em número de publicações são: *IEEE Access*, *Atmospheric Research*, *Renewable Energy*, *Energies* e *Energy*. Os três principais autores da área, para o

período analisado, são Wang, J.; Yuan-Kang Wu; Min, J.; Stoffelen, A. Em relação aos continentes, os destaques são para os continentes asiático e europeu.

### **3.3.1. Estado da Arte**

#### **3.3.1.1. Previsão do Recurso Eólico Baseada em Aprendizado de Máquina**

Modelos baseados em SVR com o objetivo de melhorar as previsões de velocidade e direção do vento de um modelo NWP em uma região da *Smøla island* são encontrados em Yakoub, Mathew e Leal (2020). O objetivo é enfrentar o mercado de curto e médio prazo por meio de melhorias nos erros sistemáticos gerais nas previsões NWP. Uma previsão do recurso eólico em curto prazo por meio de CNN é estudada em Wang *et al.* (2020). Para a previsão os autores utilizaram dados coletados em parques eólicos vizinhos e perceberam que a precisão do modelo foi superior aos modelos SVR, RR e a própria CNN com dados apenas do parque analisado.

Métodos de AM são aplicados em Yaghoubirad *et al.* (2023) para a previsão do recurso eólico em uma região específica no sudeste do Irã. Três diferentes horizontes de longo prazo são testados (6 meses, 1 ano e 5 anos) e as metodologias LSTM, GRU, CNN e CNN-LSTM são utilizadas. Posteriormente, a potência de um parque eólico, que será implantado posteriormente no local, é prevista. O método GRU apresentou maior precisão em comparação com os outros métodos testados.

Previsões de médio prazo da ECMWF são aprimoradas em Zhang *et al.* (2023) por meio de DL espaço-temporal. Uma função de perda de aprendizado multitarefa é desenvolvida para corrigir a velocidade e a direção do vento em tempo real. As habilidades para modelar e prever séries temporais do recurso eólico por meio do uso de LSTM, modelos *Nonlinear Auto-Regressive* (NAR) e *Wavelet Neural Networks* (WNN) são comparadas em Pujari *et al.* (2023). A importância da previsão precisa é analisada para melhorar a produção anual de eletricidade de um parque eólico projetado para produzir de maneira sustentável.

Métodos de redução de escala para fins agrícolas na Coreia do Sul são propostos em Shin, Min e Kim (2022). Os modelos de AM testados são RF, ELM e SVR. O RF foi considerado o algoritmo mais apropriado dos algoritmos testados para a redução de escala. Utilizando oito anos de medições de velocidade do vento em 171 estações espalhadas sobre a França, Goutham *et al.* (2021) relacionam, por meio de modelos de AM (RF e kNN), previsões obtidas por NWP com previsões observadas. O recurso eólico modelado nas análises do

ECMWF, sozinhas, apresentou erros em todas as estações distribuídas amplamente em torno de uma mediana de 1,42 m/s.

### 3.3.1.2. *Previsão da Geração Eólica Baseada em Aprendizado de Máquina*

Modelos de previsão de energia eólica para longo prazo (seis meses à frente) foram desenvolvidos em Ahmadi *et al.* (2020) usando algoritmos de aprendizado baseados em árvores (RF, árvore de decisão e outros). Os autores testaram diversas combinações de entradas variando altura de medição e intervalo de medições e os resultados foram satisfatórios. Melhorias em modelos tradicionais de RNA são encontrados em Medina e Ajenjo (2020) para a previsão da geração em curto prazo. Os autores variaram as entradas das redes e incorporaram na camada de entrada dados de uma segunda estação meteorológica além da estação de referência do parque eólico.

Um modelo de correção de erro de velocidade do vento NWP baseados em *Gated Recurrent Unit Neural Networks* (GRUNNs) para previsão da geração é proposto em Ding *et al.* (2019). Na aplicação, são consideradas as características estatísticas da série temporal para a correção de erros.

### 3.3.1.3. *Modelos Fenomenológicos (Previsão Numérica do Tempo) para a Previsão do Recurso Eólico*

Os modelos fenomenológicos incorporam a orografia, permitindo a compreensão do comportamento físico. Por meio da resolução de sistemas numéricos complexos, esses modelos geram previsões regionais e globais usando condições iniciais. Os dados históricos são de menor importância em tais modelos. É necessária a obtenção de informações sobre a rugosidade da superfície e as características dos parques eólicos para a obtenção de previsões precisas do recurso eólico (Yousuf; Al-Bahadly; Avcı, 2019). Estudos mostraram que os modelos fenomenológicos tiveram melhor desempenho em previsões eólicas em horizontes de médio e longo prazo (Hu *et al.*, 2020).

Visando melhoria nas previsões da velocidade do vento nos locais das turbinas e na altura do *hub*, Sun *et al.* (2022) desenvolvem o sistema *Weather Research and Forecasting Data Assimilation* (WRFDA) com os algoritmos 3DVAR e 4DVAR. Os autores observaram que o uso de *Data Assimilation* (DA) desenvolvido melhora a análise e a previsão da velocidade do vento usando dados de uma turbina eólica.

Paula *et al.* (2020) aplicam diferentes estratégias de AM (RF, RNA e GB) para realizar regressão em dados de velocidade do vento no horizonte de longo prazo. Dados de parques eólicos do Nordeste do Brasil foram utilizados, além de dados do Instituto Nacional de Meteorologia (INMET). Os autores concluíram que o uso da diversificação nos modelos preditivos em casos relacionados à regressão não linear pode ser benéfico, especialmente em horizontes de longo prazo.

Uma análise da capacidade do modelo WRF em simular o recurso eólico próximo a uma superfície complexa na Península de Baja – California e de rampas de vento é desenvolvida em Pereyra-Castro, Caetano e Altamirano del Razo (2021). A partir dos resultados obtidos, observou-se que em esquemas da camada limite planetária testados tendem a subestimar os dados observados, especialmente quando sistemas de mesoescala afetam a região.

#### 3.3.1.4. *Previsão do Recurso Eólico Baseada em Modelos Estatísticos*

Os métodos estatísticos necessitam de dados de séries temporais para descobrir as relações geralmente por técnicas recursivas. Fornecem previsões precisas em horizontes de curto prazo; o uso de NWP é opcional para esses modelos; baseiam-se em padrões e não utilizam nenhum modelo matemático pré-definido (Yousuf; Al-Bahadly; Avci, 2019). Ao contrário dos modelos fenomenológicos, estes são modelos de séries temporais que normalmente são empregados para caracterizar as flutuações lineares de previsões eólicas em diferentes locais e, de maneira geral, apresentam boa precisão em horizontes de curto prazo (Wang *et al.*, 2021).

Um método *calibrated regime-switching (CRS)* para previsão do recurso eólico em curto prazo é encontrado em Ezzat, Jun e Ding (2019). Essa abordagem constrói um modelo reativo de mudança de regime que tem um viés inerente devido a extrapolar os atributos das amostras na forma de previsões. Viés esse, que é corrigido por meio da introdução de uma calibração usando funções paramétricas de dois elementos (dando indicação de mudanças).

Um método chamado *Typical Event Clustering Identification (TECI)* é proposto em Li *et al.* (2020a) para pesquisar a probabilidade máxima de ocorrência de dados históricos com o indicador de similaridade. O algoritmo de agrupamento *K-means* é usado para pré-processar a velocidade histórica do vento e, posteriormente, a similaridade do conjunto de eventos de energia eólica é obtida por meio da estimativa de probabilidade empírica de sucessivos eventos históricos de rampa.

Uma análise espaço-temporal foi desenvolvida em Ezzat, Jun e Ding (2018). Os autores observaram que os campos eólicos locais são fortemente assimétricos. A partir daí, foi proposta uma metodologia de previsão do recurso eólico aproveitando a correlação espacial entre as turbinas da vizinhança, em vez de obter uma única previsão de série temporal para uma turbina ou uma única série temporal agregada para toda a fazenda.

Casciaro *et al.* (2022) propõem um EMOS para calibração de previsões do recurso e da geração eólica considerando a relação não linear entre preditores e outros observáveis climáticos que são usados como variáveis condicionantes. Os dados utilizados são obtidos no ECMWF.

### 3.3.1.5. Previsão da Geração Eolielétrica Baseada em Modelos Estatísticos

Um modelo de despacho ótimo para o dia seguinte em um sistema de armazenamento de geração eólica é encontrado em Nguyen e Le (2021). Os autores consideram as incertezas da geração em três principais etapas: a) pré-processamento; b) modelagem de série temporal; e c) método de seleção de avanço rápido. Um modelo *AC Optimal Power Flow* (AC OPF) com *Battery Energy Storage* (BES) e integração de vento por meio de técnicas de modelagem de incerteza de vento (modelo ARMA) são implementados.

Uma metodologia de previsão probabilística bivariada da geração eólica e preços é proposta em Lee, Shin e Baldick (2018), sendo dividida em três etapas: a) Metodologias individuais são implementadas e os erros de previsão são coletados (*Outliers* são detectados por meio da *RR*); b) Geração da previsão final por meio de uma combinação de várias metodologias de previsão; c) Os erros de previsão são usados para estimar a distribuição de forma fechada usando uma abordagem paramétrica baseada no algoritmo de amostragem.

Um modelo baseado na *Higher-order Multivariate Markov Chain* (HMMC) para a previsão da geração de plantas eólica e solar pode ser encontrada em Sanjari, Gooi e Nair (2020). Diferentes cenários são simulados e são considerados: a variável meteorológica do índice de calor e o procedimento de atualização dinâmica dos parâmetros.

Um método não paramétrico modificado para construir IP confiáveis é proposto em Wu *et al.* (2018a). O método LUBE foi adaptado para construir IP para a geração, com base nos dados históricos de velocidade do vento, dados determinísticos e de conjuntos NWP de diversos parques eólicos em Taiwan. Os resultados da simulação apresentaram IP com qualidade superior aos construídos usando o modelo de persistência.

Uma modelagem de desvios prováveis das previsões de geração pode ser encontrada em Becker (2018). Uma abordagem que utiliza construções *pair-copula* ou *vine copulae* para gerar cenários de alimentação de energia eólica acoplados no tempo é realizada em uma agregação de parques eólicos. Essas construções levam em consideração a propagação dos erros de previsão da geração no tempo e podem modelar estruturas de dependência complexas entre múltiplas variáveis.

Considerando que o mercado de eletricidade solicita dos parques eólicos dados de previsões pontuais, Mararakanye, Dalton e Bekker (2022) propõem variáveis explicativas que são utilizadas para treinar o estimador de densidade de *kernel* para derivar pontos agregados e previsões probabilísticas da geração a partir de pontos descentralizados.

#### 3.3.1.6. Modelos Híbridos para a Previsão do Recurso Eólico

De acordo com Yousuf, Al-Bahadly e Avci (2019), os métodos híbridos podem ser definidos como a combinação de diferentes métodos de previsão para melhorar o desempenho da previsão final. Um modelo individual tem desempenho limitado em várias situações, a modelagem híbrida reduz essas limitações buscando aproveitar o melhor de cada método combinado.

Métodos estatísticos com o objetivo de combinar conjuntos de previsões baseadas em NWP são encontrados em Zamo, Bel e Mestre (2021). Os autores observaram que as equações de pós-processamento podem se tornar inadequadas à medida que mudanças relevantes ocorrem nos modelos de NWP e que janelas deslizantes de diferentes tamanhos podem reduzir essa limitação.

Zhang *et al.* (2023a) apresentaram um modelo híbrido para previsão de velocidade do vento em curto prazo que incorpora métodos de processamento de ruído (VMD), técnicas estatísticas/estruturas de aprendizado profundo (RNN, LSTM, SVR E XGboost) e algoritmos de otimização (GWO). Um algoritmo GWO para otimizar a rede LSTM para previsão do recurso eólico é encontrado em Altan *et al.* (2021), e os resultados mostram que a otimização do LSTM usando o algoritmo GWO obteve bons resultados. Um modelo híbrido que otimiza parâmetros por meio do GWO e utiliza uma ELM regularizada para previsão do recurso eólico pode ser encontrado em Liu, Wu e Li (2019).

Levando em conta o sinal não-linear e não-estacionário da velocidade do vento original, Xiang, Deng e Hu (2019) propuseram um modelo híbrido para previsão do recurso eólico usando WT empírica, SVM e o *Bird Swarm Algorithm* (BSA). Um modelo híbrido que utiliza



WT, LSTM e GARCH para previsão do recurso eólico em curto prazo pode ser encontrado em Jiang *et al.* (2018).

Um modelo híbrido que combina Markov chains (MCh), ARIMA e *maximal overlap discrete wavelet transform* (MODWT) é encontrado em Yousuf, Al-Bahadly e Avcı (2021), chamado MODWT-ARIMA-Markov. A aplicação híbrida é usada para prever velocidades de vento em horizonte de curto prazo por meio da integração MChs com uma janela móvel de ajuste dinâmica. O mesmo MODWT é utilizado no modelo híbrido proposto em Li *et al.* (2022) combinado a modelos RF, *Improved Grey Wolf Optimization Algorithm* (IGWO) e LSTM.

Combinações utilizando arquiteturas *Transformer* (*LogSparse Transformer*, *Informer* e *Autoformer*) são utilizadas em Bentsen *et al.* (2023) para a previsão do recurso eólico. *Graph Neural Network* (GNN) é usada para extrair dependências espaciais e com diferentes funções de atualização para aprender correlações temporais (implementadas usando diferentes arquiteturas de RNA, incluindo LSTM e MLP). Santos *et al.* (2023) propõem uma modelagem híbrida para a previsão do recurso eólico utilizando *Graph Attention Network* (GAT) e *GraphSAGE*. O modelo *ensemble* utiliza dados holandeses e aplica a metodologia a diferentes horizontes de previsão e investiga fenômenos espaço-temporais que sustentam o recurso eólico.

Ahmadi e Khashei (2022) combinam diferentes modelos de previsão do recurso eólico (híbridos e individuais), utilizando pré-processamento de dados por meio do KF e uma estrutura baseada em lógica fuzzy para modelar padrões lineares e não lineares.

Um modelo híbrido baseado em três módulos é proposto em Yang, Hao e Hao (2023). a) pré-processamento de dados (usando ICEEMDAN e VMD); b) modelagem de frequência mista (por meio de modelos ELM simples e regularizado); e c) previsão de *ensemble* foram projetados para construir o sistema de previsão desenvolvido usando multi-objective *Salp Swarm Algorithm* (MSSA). Wang, Li e Bai (2018) combinam em uma modelagem híbrida baseada em pós-processamento para previsão do recurso eólico os modelos ICEEMDAN (usado para a previsão propriamente dita) e ARIMA (usado para determinar as melhores variáveis de entrada).

Dois modelos probabilísticos para previsão da geração são propostos em Gilbert, Browell e McMillan (2019): a) Previsões determinísticas de geração no nível da turbina são utilizadas como variáveis explicativas em um modelo de previsão probabilístico para uma fazenda eólica; e b) uma *Bottom-up Hierarchical Approach* (BHA) prevendo por meio da distribuição preditiva conjunta da potência de saída das turbinas individuais.

Um modelo híbrido baseado em pré-processamento de dados e problema de otimização multiobjetivo, uma variação do AG (de ordenação não dominada com três funções objetivos) e quatro modelos (dois híbridos não lineares e dois lineares) é proposto em Zhang, Dong e Wang (2019), obtendo boa precisão na previsão da velocidade do vento.

Um novo modelo híbrido é proposto em Duan *et al.* (2022), o qual é composto dos seguintes modelos ICEEMDAN (para pré-processamento), EMD, CNN, RNN e uma rede de regressão linear considerando o erro histórico. O pré-processamento ICEEMDAN produz resultados de previsão melhores do que aqueles sem decomposição ICEEMDAN. Dois novos modelos de calibração estatística para previsões meteorológicas obtidas a partir de modelos NWP são propostos em Gomes *et al.* (2021). Os modelos generalizam as técnicas de pós-processamento *Geostatistical Output Perturbation* (GOP) e EMOS combinando-as com modelos dinâmicos bayesianos.

Um *sticky Hierarchical Dirichlet Process* - HMM (sHDP-HMM) para investigar a capacidade do sistema WRF em prever a velocidade e direção do vento local é encontrado em Mastrantonio *et al.* (2018). O comportamento do conjunto de dados é descrito pelo *Joint Projected and Skew Normal* (JPSN), o HMM fornece a representação da evolução do tempo com a mudança de estados homogêneos.

Um modelo de RNA é usado em Couto e Estanqueiro (2022) visando melhorar a precisão das previsões da geração explorando todas as capacidades de previsões NWP (características meteorológicas e o uso de dados de grade espacial). Combinar o uso de informações espaciais do NWP com dados meteorológicos de entrada revelou ser a abordagem que produz os resultados mais precisos. Um modelo híbrido de NWP e *Gaussian Process Regression* (GPR) para a previsão do recurso eólico próximo à superfície até 72 h à frente é encontrado em Hoolohan, Tomlin e Cockerill (2018).

A PT é utilizada em Carneiro *et al.* (2022) para integrar as previsões do recurso eólico desenvolvidas por três diferentes modelos de AM: MLP, RBF e SOM. Testada em dois locais diferentes, a metodologia conseguiu melhorar a precisão dos resultados obtidos pelos modelos individuais. Um modelo híbrido que combina RNA e ARIMA para previsão do recurso eólico em curto prazo usando estatísticas multivariadas é encontrado em Camelo *et al.* (2018).

Um sistema híbrido robusto baseado em três módulos é desenvolvido em Wang *et al.* (2022). EEMD é usado para pré-processamento dos dados do recurso eólico; GWO é utilizado para otimizar os parâmetros de diferentes RNA; módulos de avaliação de modelo, que combinam o desempenho de cada algoritmo, são desenvolvidos em várias etapas. A conversão

do recurso eólico em geração elétrica também é considerada. Em Chen *et al.* (2021) é possível encontrar outra aplicação do EEMD juntamente com AG e LSTM para previsão em curto prazo do recurso eólico.

Um modelo híbrido *Bidirectional Long Short-Term Memory* (BiLSTM) para previsão do recurso eólico quase em tempo real é proposto em Joseph *et al.* (2023). O modelo proposto foi comparado com modelos comparativos, incluindo LSTM autônomo e híbrido, RNN, MLP e RF e o BiLSTM apresentou melhor desempenho. Li, Wu e Liu (2018) propõem um modelo híbrido que combina os seguintes modelos: WT (para decomposição de séries de velocidade do vento), RELM (preditores secundários para os dados de erro) e LSTM (preditor principal para os dados decompostos).

Um sistema de previsão do recurso eólico em múltiplas etapas é proposto em Zhang *et al.* (2020). É realizado um pré-processamento por meio de WD, são combinadas as características dos algoritmos NAR e NARX e usado a SVM como um método de pós-processamento. Um modelo híbrido que utiliza *Broyden-Fletcher-Goldfarb-Shanno* (BFGS) para geração de subséries de dados eólicos anteriormente decompostos por meio de WD e VMD é encontrado em Liu *et al.* (2018).

Um sistema híbrido de previsão do recurso eólico de dois estágios é proposto em Zhang *et al.* (2019a) com base na abordagem de pré-processamento de dados (usando VMD), algoritmo de otimização multiobjetivo aprimorado chamado *Improved Multi-Objective Dragonfly Algorithm* (IMODA), correção de erros e estratégia de conjunto não linear (modelo ELM). Um modelo híbrido para previsão do recurso eólico é proposto em Hu e Chen (2018). Na modelagem é utilizado o ELM modificado e uma LSTM que tem suas camadas determinadas por um algoritmo de evolução diferencial.

Jiang *et al.* (2023) propõem um modelo com múltiplas etapas usando *Convolutional gated recurrent unit* (CGRU). Baseado na *secondary decomposition* (SD) e na otimização *extreme gradient boosting* (XGBoost), a série é decomposta em múltiplas subséries, e as características da divisão de frequência das flutuações do recurso são extraídas. O modelo adaptou-se à dependência de longo prazo e extraiu informações efetivas.

Em Mehdizadeh, Kozekalani Sales e Safari (2020), modelos AR, ARMA, *Moving Average (MA)*, RF e *Multivariate Adaptive Regression Splines* (MARS) (de AM) foram combinados em 6 modelos híbridos. Os modelos híbridos superaram o RF e MARS individuais para estimativas do recurso eólico de curto e longo prazo. Os modelos RF-AR e MARS-AR forneceram os melhores desempenhos.

Wang *et al.* (2023) propõem uma modelagem híbrida para previsão do recurso eólico que utiliza *Wavelet Soft Threshold Denoising* (WSTD) para eliminação de ruído, coeficiente máximo de informação, que mede as relações lineares e não lineares entre os dados históricos analisados, CNN com modificações para a realização das previsões. Uma modelagem com CNN e SVM para a previsão do recurso eólico é proposto em Mi, Liu e Li (2019), sendo utilizada análise do espectro singular e EMD para extrair características dos dados de vento. Yu *et al.* (2018) utilizam WT para decompor séries históricas do recurso eólico e propõem uma modelagem híbrida que combina os seguintes modelos: RNN, SVM, GRU e LSTM.

Um novo modelo híbrido que utiliza uma variação da WT combinada ao ARIMA foi proposto em Singh e Mohapatra (2019) utilizando apenas os dados anteriores para a previsão da velocidade do vento em curto prazo. O modelo foi comparado ao ARIMA e ao WT-ARIMA, obtendo melhor desempenho.

Quatro modelos híbridos distintos para a previsão do recurso eólico são propostos e, posteriormente, integrados em Chem *et al.* (2019). *Echo State Network* (ESN) foi utilizado para realizar a combinação dos diferentes resultados obtidos individualmente.

Um método híbrido para a previsão do recurso eólico pode ser encontrado em Zhang *et al.* (2019). O modelo é baseado em *Online Sequential Outlier Robust Extreme Learning* (OSORELM), no pré-processamento de dados por meio do *hybrid mode decomposition* (HMD) e utiliza *crisscross optimization* (CSO) para otimização de parâmetros.

Uma nova abordagem híbrida de extração de recursos é desenvolvida em Wu, Wu e Zhu (2019). *Density-Based Spatial Clustering of Applications with Noise* (DBSCAN) é usado para selecionar as amostras representativas para treinamento. A extração profunda de recursos pode preservar a maioria das informações e eliminar informações redundantes nos dados. Os recursos extraídos dos dados históricos brutos são alimentados em redes LSTM para previsão do recurso eólico.

### 3.3.1.7. Modelos Híbridos para a Previsão da Geração Eolielétrica

Em Cui *et al.* (2019) é desenvolvida uma *probabilistic Wind Power Ramp Forecasting* (p-WPRF), dividida em quatro principais etapas e combinando modelos: a) Um método de aprendizado de máquina que gera vários conjuntos de previsões determinísticas; b) Um *generalized Gaussian mixture model* (GGMM) para ajustar uma função de distribuição de probabilidade real de erros de previsão de geração; c) Um método de transformação inversa de

GGMM para gerar um conjunto de cenários de erros de previsão de geração; e d) uso de um algoritmo de porta oscilante para extrair as WRPs nas previsões de geração.

Um modelo híbrido que combina CNN e VMD é proposto em Yildiz *et al.* (2021), visando a previsão precisa da geração. A metodologia é dividida em duas etapas: a) extração de recursos por VMD e a conversão desses recursos em imagens; b) previsão da geração pela CNN. Dados meteorológicos e de geração foram empregados como conjunto de dados.

Um modelo híbrido que combina LSTM, *improved dynamic swinging door algorithm* (ImDSDA) e agrupamento fuzzy C-means (FCM) é encontrado em Cui *et al.* (2023). O modelo proposto prevê a geração em curto prazo e considera eventos de rampa (detectados e classificados por meio do ImDSDA e FCM para serem utilizados posteriormente na previsão usando LSTM).

Pierro *et al.* (2022) avaliam os benefícios alcançados por meio das previsões solares e eólicas na redução de desequilíbrios e pelo fortalecimento da rede nacional de transmissão conectando as áreas do mercado italiano. Os autores utilizaram modelos híbridos físicos e de AM e concluíram que discrepâncias significativas foram encontradas na região estudada quando apenas modelos físicos foram usados em comparação com observações.

Visando obter uma previsão de geração mais precisa, Li *et al.* (2021) propõem uma metodologia híbrida que usa WRF (para gerar previsões do recurso eólico), HMM (para explorar a autocorrelação temporal do erro das previsões obtidas pelo WRF e a correlação não linear entre o resultado do WRF e o erro), FCM (para dividir apropriadamente o espaço de estado de erro).

Um modelo híbrido que combina VMD, CNN e GRU para previsão de curto prazo da geração é proposto em Zhao *et al.* (2023). O modelo utiliza dados meteorológicos e de geração elétrica em um parque eólico na China. O VMD é usado para reduzir a volatilidade das sequências do recurso eólico, a CNN extrai características espaciais completas dos dados de geração e a GRU extrai características temporais dos dados históricos utilizados na entrada. Um método GRU bidirecional baseado em estrutura bayesiana foi proposto em Liu *et al.* (2023) para previsão da geração de curto prazo. Uma arquitetura de codificador-decodificador foi combinada com a modelagem GRU bidirecional de série temporal para melhorar a precisão da previsão.

Uma abordagem não paramétrica de previsão probabilística da geração é proposta em Wang *et al.* (2022a). A distribuição de probabilidade da geração é especificada pela função

quantil *spline*. Além disso, uma RNN autorregressiva é treinada para aprender todos os parâmetros da *spline* quadrática e uma função de perda baseada em CRPS é proposta.

Um modelo híbrido para a previsão da geração é proposto em Li *et al.* (2021a). O modelo combina SVR e CS e melhorou a precisão da previsão. O SVR realiza a tarefa de previsão e o modelo CS é utilizado para otimizar os hiperparâmetros com base em uma comparação abrangente de múltiplos algoritmos de otimização de inteligência de enxame.

Um modelo híbrido é encontrado em Sun e Zhao (2020), combinando o *Variational Optical Flow* (VOF) (para eliminar as características não estacionárias da série de geração bruta), a operação de convolução na rede LSTM (mecanismo preditor) e análise de erros. Shahid, Zameer e Muneeb (2021) propõem um novo modelo híbrido com AG e LSTM, chamado Genétic LSTM (GLSTM) para prever a geração em parques eólicos na Europa. Aproveitando o melhor do AG, são otimizados as janelas e o número de neurônios das camadas LSTM.

Um modelo híbrido para previsão da geração em horizonte de curto prazo usando CEEMD com ruído adaptativo, SVR e CNN é proposto em Zhu, Su e Li (2022). O CEEMD visa melhorar a extração da informação original. O modelo proposto obteve o melhor desempenho quando comparado a outros modelos (foram utilizados dados reais da geração de um parque eólico). No modelo híbrido proposto em Du *et al.* (2019), um CEEMD melhorado, WNN e *Multi-objective Moth-Flame Optimization* (MOMFO) são usados para a previsão em múltiplas etapas da geração.

Li *et al.* (2020a) propõem um modelo híbrido para prever a geração. O modelo combina WD, SVM e um algoritmo de busca atômica melhorado. Os dados são decompostos em vários componentes durante a previsão e diversas informações foram obtidas visando a redução do erro de previsão que as rampas de vento podem causar. Uma abordagem híbrida multiobjetivo e baseada em otimização de parâmetros para a previsão do recurso eólico é encontrada em Li e Jin (2018). Os modelos aplicados são: *multi-objective ant lion algorithm* (MOALO) e LS-SVM.

Um método de previsão da geração de curto prazo e uma análise de incerteza baseado no FCM- *Whale Optimization Algorithm* (WOA)-ELM-GGMM foram propostos em Gu *et al.* (2023). FCM agrupa previsões NWP e dados do parque eólico; WOA e ELM para otimização de parâmetros; e o GGMM foi usado para calcular com precisão a distribuição de densidade de probabilidade de erro de previsão. Kim e Hur (2018) desenvolvem uma modelagem híbrida para previsão da geração em curto prazo e que faz previsões de conjunto combinando os modelos ARIMA, *spatiotemporal kriging* e regressão polinomial, considerando modelos NWP.

Um modelo e procedimento para previsões determinísticas e probabilísticas da geração é proposto em Wu *et al.* (2022). A pesquisa se concentra em tecnologias de pré-processamento de dados e esquemas de aprendizado usando modelos baseados em inteligência artificial. Características importantes da velocidade do vento foram extraídas por PCA e EMD e a previsão da geração foi realizada por RNA e XGBoost.

Uma previsão em múltiplas escalas espaciais é proposta em Yan *et al.* (2018). Uma rede de mapeamento *multi-to-multi* (m2m) baseada em *Stacked Denoising Auto-Encoder* (SDAE) é desenvolvida. Várias previsões NWP em uma região são corrigidas com base no SDAE para gerar entradas que, posteriormente, são combinadas a vários SDAE com diversos parâmetros de modelo e recursos de entrada.

Uma estrutura híbrida que utiliza método de imputação múltipla, amostragem de *Gibbs* e especificações totalmente condicionais para especificar distribuições variável por variável para previsão da geração considerando dados com falhas é encontrada em Wen *et al.* (2023).

Na Tabela 3.3 são apresentados os artigos mais citados de acordo com a presente revisão de literatura, considerando cada uma das abordagens de previsão (fenomenológica, estatística, AM e modelos híbridos). O número de citações foi obtido por meio do google acadêmico.

Tabela 3.3 - Resumo das metodologias de previsão eólica mais citadas

Referências	Método de Previsão	Horizonte de Previsão	Meta de Previsão	Escala Espacial de Previsão	Citações ( <i>google scholar</i> )
(Singh; Mohapatra, 2019)	WT E ARIMA	minutos	velocidade do vento	campo único	351
(Hu; Chen, 2018)	ELM e LSTM	horário e minutos	velocidade do vento	campo único	229
(Du <i>et al.</i> , 2019)	CEEMD, WNN e MOMFO	minutos	geração eólica	regional	202
(Shahid; Zameer; Muneeb, 2021)	AG e LSTM	horário	geração eólica	regional	169

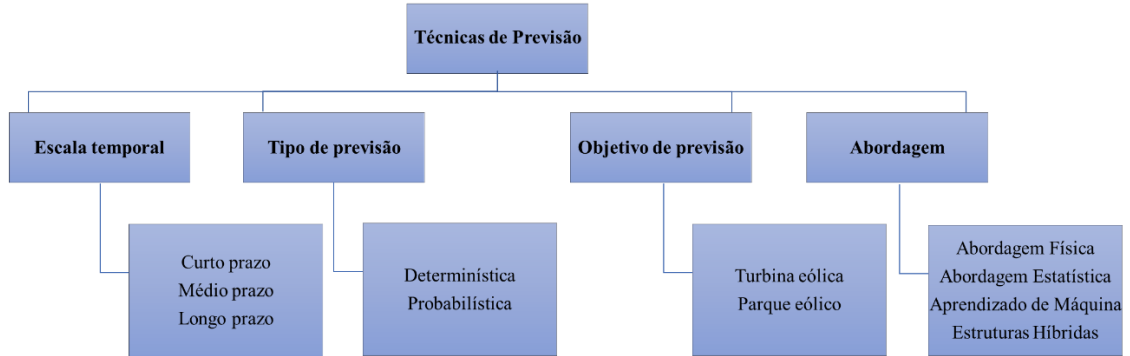
Fonte: Próprio autor.

### 3.3.2 Classificação dos artigos analisados

As metodologias de previsão eólica são classificadas de acordo com: a) abordagem (modelos físicos, estatísticos, híbridos e de AM); b) horizonte de previsão (curto, médio e longo prazo); c) previsão direta ou indireta (direta: a previsão da geração de uma turbina ou de parque

eólico; indireta: a geração é estimada após a previsão do recurso eólico); e d) escala de previsão espacial (previsão de campo único ou regional). Na Figura 3.17 é apresentado um esquema referente à classificação das técnicas de previsão eólica.


Figura 3.17 - Classificação dos métodos de previsão da geração e do recurso eólico



Fonte: Adaptado de Wang *et al.* (2021).

Na Figura 3.18 é apresentada a porcentagem de artigos que aplicam as diferentes abordagens; a modelagem híbrida, especialmente em modelagens que realizam pré ou pós-processamento de dados e otimização de estruturas e parâmetros, representaram 67% do total de artigos que compõem a revisão.

Figura 3.18 - Classificação de acordo com a abordagem de previsão




Fonte: Próprio autor.

Na Figura 3.19 é mostrada a classificação das aplicações de acordo com o horizonte de previsão: curto, médio e longo prazo. Dos artigos analisados, 78% preveem em horizonte de curto prazo.



Figura 3.19 – Classificação de acordo com o horizonte de previsão

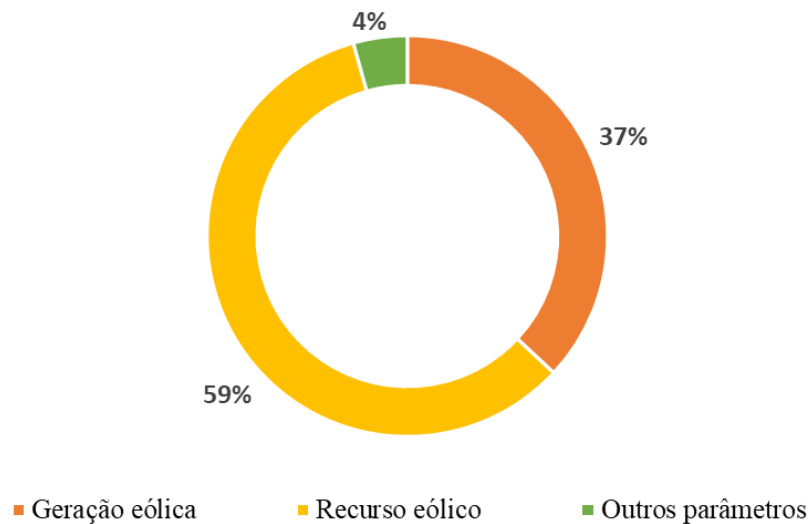


Fonte: Próprio autor.

A previsão eólica de curto prazo é importante para planejamento de despacho de carga. Em horizonte de médio prazo é relevante na comercialização e na gestão dos sistemas de energia. As previsões em horizontes de longo prazo são utilizadas no planejamento do sistema como um todo e para a orientação da programação de manutenções visando a otimização do custo operacional (Zhao; Wei; Su, 2016).

Na Figura 3.20 são apresentados os objetivos de previsão nas diferentes aplicações analisadas.

Figura 3.20 – Classificação de acordo com a meta de previsão,




Fonte: Próprio autor.

As aplicações diretas compreendem 37% das aplicações analisadas (onde a previsão é realizada visando obter dados da geração). Um total de 59% usa previsão indireta, tendo o recurso eólico como meta de previsão. Em um total de 4% das aplicações, além de prever a geração ou o recurso eólico, predizem outros parâmetros como a direção do vento e índice e calor. Desse total também estão incluídos artigos que realizaram a previsão de eventos de rampa eólica (as flutuações súbitas do recurso ou da geração propriamente dita).

Na Figura 3.21 são resumidos os dados referentes à classificação da escala espacial de previsão. As previsões de campo único representam 45% do total e contemplam as previsões utilizando dados do recurso eólico coletados em um só local ou da geração que seja de um parque ou turbina eólica específica. As previsões regionais incluem as previsões para dados do recurso eólico coletados em diferentes localidades e aquelas que utilizam dados de geração de mais de um parque eólico.

Figura 3.21 – Classificação com base na escala espacial de previsão




Fonte: Próprio autor.

### 3.3.3 Métricas de Avaliação de Desempenho

Na Figura 3.22 são mostradas as métricas de erro mais utilizadas para avaliar a acurácia dos métodos que compõem a presente revisão (incluindo probabilísticas e determinísticas).

Figura 3.22 – Métricas de erro para avaliar a precisão dos métodos: a) determinísticas e b) probabilísticas



Fonte: Próprio autor.

As medidas de desempenho mais aplicadas nos artigos são RMSE, MAE, MAPE e R com 30%, 28%, 20% e 11%, respectivamente. É importante destacar que as medidas de desempenho devem ser aplicadas em conjunto para realizar uma avaliação global das metodologias. Alguns parâmetros probabilísticos como PINAW e PICP também foram encontrados na avaliação de metodologias de previsão, mas em menor quantidade.

### 3.3.4 Discussão: Análise Global

Por meio desta *qSLR*, foram identificados 89 artigos relevantes para responder às perguntas de pesquisa relacionadas à previsão eólica. Com base nos dados extraídos desses artigos, foram reunidas algumas evidências sobre o assunto.

1. A maioria dos modelos baseados em *ensemble* não consideram informações espaço-temporais, mas esta informação pode ser considerada na concepção dos modelos de aprendizagem para aumentar a precisão da previsão. Os métodos podem ser explorados individualmente para cada um dos componentes dos dados da série temporal e, em seguida, os valores previstos dos componentes combinados para obter a previsão (Prema *et al.*, 2021);
2. A revisão teórica desenvolvida em Yousuf, Al-Bahadly e Avci (2019) observou que os erros mais significativos foram observados para os modelos da abordagem física, enquanto os modelos híbridos apresentaram melhores desempenhos em todos os horizontes temporais;

3. Como as séries temporais do recurso eólico e da geração podem ser tratadas como sinais, muitos pesquisadores têm utilizado métodos de processamento de sinal para decompor esses sinais em diferentes subséries. Daí, os resultados previstos de todas as subséries são agregados para produzir previsões com base nos dados originais. Atualmente, três tipos de métodos de processamento de sinal têm sido amplamente utilizados para pré-processar séries históricas de dados eólicos: abordagens baseadas em WD (Zhang *et al.*, 2020; Yousuf, Al-Bahadly, Avci, 2021; Jiang *et al.*, 2018); métodos baseados em decomposição de modo, tais como, ICEEMDAN, EEMD, EMD e VMD (Duan *et al.*, 2022; Wang *et al.*, 2022; Zhang; Dong; Wang, 2019; Mi; Liu; Li, 2019) e modelos baseados em análise de espectro singular (SSA) (Wang *et al.*, 2021);
4. O uso de pré-processamento de dados permite que os modelos sejam mais propensos a aprender as características não lineares do recurso eólico. “*A eficácia da combinação de processamento de dados foi verificada tanto no aspecto da precisão quanto da eficiência*” (Liu; Chen, 2019);
5. Da mesma forma que foi observado na revisão sobre previsão solar, na revisão eólica os modelos de pré e pós processamento de dados e o uso de ferramentas de otimização nas modelagens híbridas têm melhorado a precisão nas modelagens híbridas;
6. Do total de artigos analisados, quase 70% foram baseados em combinações híbridas de diferentes modelos e, a partir dos resultados, foi possível observar que esses modelos vêm obtendo melhores desempenhos que modelos aplicados individualmente;
7. Os modelos fenomenológicos incorporam a orografia, permitindo a compreensão do comportamento físico. Necessitam da obtenção de informações sobre a rugosidade da superfície e as características dos parques eólicos para a obtenção de previsões precisas do recurso eólico (Yousuf; Al-Bahadly; Avci, 2019);
8. Os modelos fenomenológicos funcionam melhor, em termos de precisão, nas previsões eólicas em horizontes de médio e longo prazo (Hu *et al.*, 2020);
9. A previsão eólica ligada à agregação de parques eólicos tem sido bastante aplicada por usuários e operadores de sistemas elétricos para embasar estudos de estabilidade e preços de energia em sistemas com participação elevada da geração associada (Becker, 2018).

### 3.3.5 Discussão: Análise por Técnica

Considerando as técnicas aplicadas individualmente ou em modelos híbridos, alguns pontos devem ser considerados:

A SVR tem sido bastante utilizada de forma individual (WANG *et al.*, 2020) e combinada a outras metodologias. Foi relevante para a melhoria de previsões em modelos NWP (Yakoub; Mathew; Leal, 2020); foi aplicado para redução de escala visando o uso agrícola (Shin; Min; Kim, 2022); também foi utilizada em diferentes estruturas híbridas: uma onde a SVR é combinada com uma VMD usada para processamento de ruído e GWO (Zhang *et al.*, 2023a); combinada a CS usada para otimização de parâmetros (Li *et al.*, 2021a); e combinada a CEEMD e CNN (Zhu; Su; Li, 2022).

Redes do tipo LSTM têm sido frequentemente encontradas em diferentes metodologias para a previsão seja do recurso eólico como também para a previsão da geração. Além disso, tem sido encontrada em modelagens híbridas (Hu; Chen, 2018) e aplicada individualmente (Pujari *et al.*, 2023). Combinada a CNN e aplicada individualmente, a LSTM foi testada em Yaghoubirad *et al.* (2023). Algoritmos como o GWO e AG foram aplicados para otimização dos parâmetros da rede LSTM, obtendo bom desempenho em diferentes aplicações (Li *et al.*, 2022; Altan *et al.*, 2021; Shahid; Zameer; Muneeb, 2021). Além da otimização de parâmetros, a LSTM, em modelagens híbridas, também foi combinada a modelos como VMD, EEMD e WT que pré e pós processamento de dados (Zhang *et al.*, 2023a; Chen *et al.*, 2021; Jiang *et al.*, 2018; Yu *et al.*, 2018; Sun; Zhao, 2020).

As redes CNN foram implementadas individualmente e combinadas a LSTM em Yaghoubirad *et al.* (2023); individualmente em Wang *et al.* (2020) e tendo um desempenho superior a rede SVR; em diversas modelagens híbridas onde as redes CNN são utilizadas, o pré-processamento foi implementado por meio de diferentes modelos: EMD, VMD, ICEEMDAN e WT (Zhao *et al.*, 2023; Duan *et al.*, 2022; Mi; Yildiz *et al.*, 2021; Liu; Li, 2019).

A ELM foi testada para redução de escala (Shin; Min; Kim, 2022); foi aplicada em modelagens híbridas que otimizam parâmetros por GWO (Liu; Wu; Li, 2019); e, com bom desempenho, combinada a modelos que pré-processam dados por meio de ICEEMDAN e VMD (Yang; Hao; Hao, 2023); com pré-processamento (VMD) e otimização de parâmetros (IMODA) combinados a ELM (Zhang *et al.*, 2019a).

NWP são frequentemente utilizados, especialmente, em modelagens que visam usar seus dados para comparação e avaliação de desempenho (GOUTHAM *et al.*, 2021) e, em alguns

casos, visando melhorar as suas previsões que algumas vezes apresentam falhas ou erros (Couto; Estanqueiro, 2022; Yakoub; Mathew; Leal, 2020; Ding *et al.*, 2019; Yan *et al.*, 2018). Algumas aplicações fazem combinações de diferentes NWP (Gu *et al.*, 2023; Zamo; Bel; Mestre, 2021) e outros propõem modelos de calibração para NWP (Gomes *et al.*, 2021). Previsões obtidas em ECMWF foram frequentemente utilizadas. Alguns modelos propõem aprimoramentos nessas previsões (Zhang *et al.*, 2023; Goutham *et al.*, 2021); e calibradas em Casciaro *et al.* (2022).

As GRU são ferramentas aplicadas de diferentes formas na previsão eólica. Aplicadas individualmente, apresentam bom desempenho em aplicações em horizontes de longo prazo, sendo superior a CNN, LSTM e CNN-LSTM combinadas (Yaghoubirad *et al.*, 2023); são aplicadas no modelo híbrido de múltiplas etapas proposto em Jiang *et al.* (2023) e individualmente em Yu *et al.* (2018); em Zhao *et al.* (2023), com pré-processamento por meio de VMD, a GRU foi aplicada para extrair características temporais dos dados de entrada. Obteve bom desempenho em longo prazo, mas também foi aplicada de forma satisfatória na previsão de curto prazo (Liu *et al.*, 2023). A GRU tem generalizado com maior precisão que redes do tipo LSTM (Ding *et al.*, 2019).

Os modelos AR, do tipo NAR e NARX têm sido frequentemente utilizados em modelagens híbridas e, em muitas aplicações, combinado a pré-processamento de dados por meio de WD (Zhang *et al.*, 2020). Aplicações individuais também foram encontradas, especialmente para comparação com o desempenho de outros modelos de AM (Pujari *et al.*, 2023). As RNA baseadas em modelos *feedforward* e nas WD, chamadas WNN, vêm sendo utilizadas na previsão do recurso eólico (Pujari *et al.*, 2023) e na previsão da geração em modelagens híbridas de múltiplas etapas (Du *et al.*, 2019).

Metodologias que decompõem dados previamente por meio da WT são utilizadas em diversos trabalhos (Li *et al.*, 2022; Yousuf; Al-Bahadly; Avci, 2021; Zhang *et al.*, 2020; Singh; Mohapatra, 2019; Xiang; Deng; Hu, 2019; Jiang *et al.*, 2018; Li; Wu; Liu, 2018; Yu *et al.*, 2018; Liu *et al.*, 2018; Li *et al.*, 2020a). Na maior parte das aplicações, o trabalho prévio de decomposição de dados contribuiu para melhorias no desempenho preditivo dos modelos e no aumento da precisão dos resultados.

Além do uso do WT para decomposição e reconstrução de séries de dados, o modelo VMD foi bastante aplicado em modelagens híbridas para a mesma finalidade (Zhang *et al.*, 2023a; Yang; Hao; Hao, 2023; Zhao *et al.*, 2023; Yildiz *et al.*, 2021; Zhang *et al.*, 2019a); em aplicações onde também é utilizado o WD (Liu *et al.*, 2018).

ELM simples e regularizadas foram utilizadas na previsão eólica (Shin; Min; Kim, 2022; Yang; Hao; Hao, 2023); como também em modelagens híbridas que utilizam o GWO para otimizar os parâmetros da ELM (Liu; Wu; Li, 2019); aplicável para previsão secundária em dados previamente decompostos por WD onde a previsão primária é realizada por um modelo LSTM (Li; Wu; Liu, 2018; Hu; Chen, 2018). Decomposição de dados por modelo VMD também foi utilizada para aplicação posterior em ELM (Zhang *et al.*, 2019a). Apresentou bons resultados na previsão de curto prazo e utilizando dados decompostos, sejam por WT ou por modelos de decomposição de modo (como VMD, EMD e outros).

Como na previsão solar, na previsão eólica o modelo RF apresentou boa aplicabilidade seja individualmente (Goutham *et al.*, 2021; Shin; Min; Kim, 2022), como também em parte de modelagens híbridas (Mehdizadeh; Kozekalani Sales; Safari, 2020).

### 3.4 Considerações Preliminares

A proposição de modelos precisos de previsão solar e eólica depende de diferentes incertezas e requer uma análise detalhada do problema e definição das variáveis a serem consideradas. Previsões solares e eólicas de alta precisão podem reduzir o custo líquido de geração, trazendo impactos positivos para a segurança da rede. Para atingir esses objetivos, são necessários dados solares e eólicos confiáveis e análises precisas das condições ambientais que possam interferir nesses recursos.

Artigos de revistas especializadas, com foco em técnicas de previsão solar e eólica, foram analisados. Devido ao grande número de artigos disponíveis, foi definido um protocolo de revisão baseado em uma adaptação do *SLR* visando uma escolha esquematizada, atendendo aos objetivos da pesquisa. Conforme apresentado na revisão, foram destacados alguns pontos relevantes que podem contribuir para o aprimoramento de pesquisas futuras.

Cada abordagem contemplada no presente estudo tem sua peculiaridade. As técnicas estatísticas são capazes de explicar os motivos das previsões, o que não acontece com as técnicas de AM. No entanto, as técnicas de AM têm um desempenho melhor do que os métodos estatísticos. Por outro lado, os métodos físicos, ferramentas importantes quando são necessários horizontes de longo prazo, possuem limitações quanto à sua complexidade, inerentes aos processos atmosféricos.

Em contrapartida, as metodologias hibridizadas têm se apresentado como a principal tendência para pesquisas futuras tanto na previsão eólica (67%) quanto na solar (42%): estão

presentes na maioria das contribuições selecionadas e mostram potencial para destacar o que há de melhor em cada técnica ou abordagem, aumentando a precisão das aplicações. O pré-processamento de dados, para aplicação na modelagem de previsão, e os métodos de pós-processamento, como aqueles que utilizam erros de previsão para gerar melhores resultados, apresentam erros minimizados, em comparação ao simples uso de preditores individuais.

Os outros aspectos considerados na análise são: horizonte de previsão, meta de previsão, escala espacial e desempenho. A presente análise identificou uma tendência crescente na aplicação de sistemas híbridos, principalmente combinando técnicas de previsão individual com metodologias que reduzem a dimensionalidade dos dados de entrada e otimizam os parâmetros do modelo.

Na análise solar, a maioria das aplicações usa horizontes de previsão de curto prazo; na maioria dos casos, os alvos esperados são a irradiação solar (indireta) e a geração FV (direta). Em relação à escala espacial, a maioria das metodologias são aplicadas em locais específicos (64%). Na análise eólica, 78% das aplicações usam horizonte de curto prazo; 59% preveem a geração e 37% o recurso eólico. Quanto à escala espacial, está bastante equilibrado o percentual de aplicações em previsão de campo único (55%) e regionais (45%).

Modelos de previsão, aplicados a diferentes horizontes, e considerando grandes áreas com diferentes condições ambientais, podem ser uma opção interessante para mitigar os impactos da intermitência solar e eólica nos sistemas elétricos, programando recursos de *backup* para momentos de baixos níveis da geração de parques FV e eólicos.

Neste Capítulo foi apresentado um levantamento bibliográfico relacionado aos temas de previsão solar e eólica. O período analisado contempla de janeiro de 2015 a março de 2021, no caso da análise solar, e de janeiro de 2018 a março de 2023, no caso da análise eólica. Por meio deste levantamento bibliográfico, foi possível constatar que, no período assinalado, em ambos os casos, existe uma tendência ao uso de metodologias híbridas e *ensemble* (que combina diferentes abordagens ou metodologias buscando obter o melhor de cada uma). No próximo Capítulo serão apresentadas e detalhadas as metodologias de conjunto (*ensemble*).

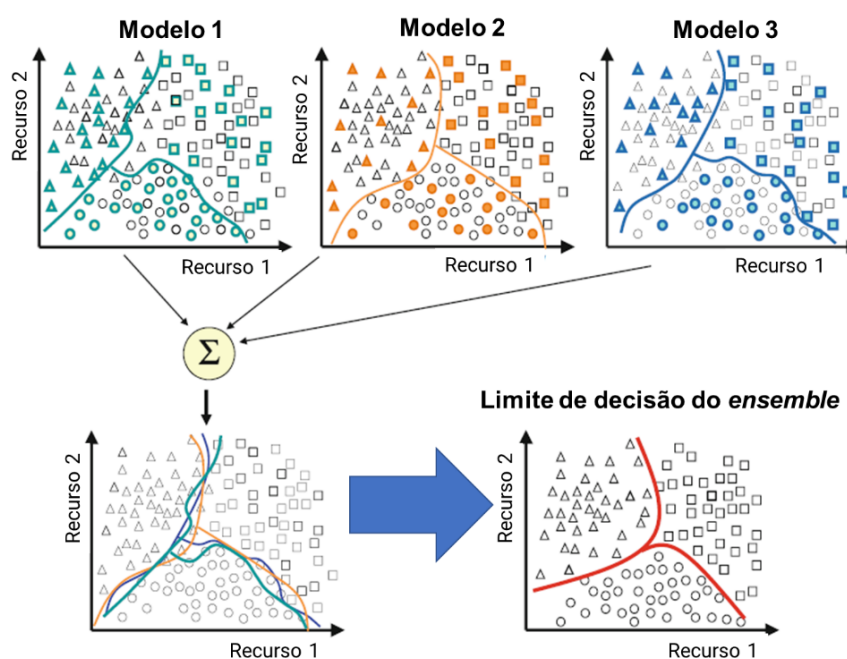


#### 4 PREVISÕES DE CONJUNTO (*ENSEMBLE*)

Os métodos *ensemble* visam reduzir a variância dos modelos aplicados individualmente e melhorar a generalização, que pode ser realizada por meio de diferentes metodologias. O princípio básico por trás de qualquer estratégia de conjunto é pesar alguns modelos e combinar suas previsões individuais para melhorar o desempenho da previsão. É importante que seus componentes tenham diversidade e precisão (Rokach, 2019; Zhou, 2012; Bian; Wang, 2007). A combinação de previsões de vários modelos adiciona um viés que, por sua vez, diminui a variação de um único modelo treinado. Portanto, ao reduzir a variação nas previsões, o conjunto pode superar qualquer modelo individual (Livieris *et al.*, 2020). Os modelos *ensemble* vêm melhorando a precisão das previsões individualizadas (Carneiro *et al.*, 2022; Yang; Yang, 2020; Bremnes, 2019; Abuella; Chowdhury, 2019).

De acordo com Zhang e Ma (2012), existem muitas formas de se combinar modelos de previsão. Os autores ressaltam que a combinação das saídas dos modelos individualizados pode não levar necessariamente a um desempenho melhor do que o melhor modelo entre os analisados, mas a combinação reduz a probabilidade de escolher um modelo com um desempenho ruim. Os modelos *ensemble* reduzem a variância do conjunto de modelos, como é demonstrado na Figura 4.1.

Figura 4.1 - Redução de variabilidade usando sistemas *ensemble*



Fonte: Adaptado de Zhang e Ma (2012).

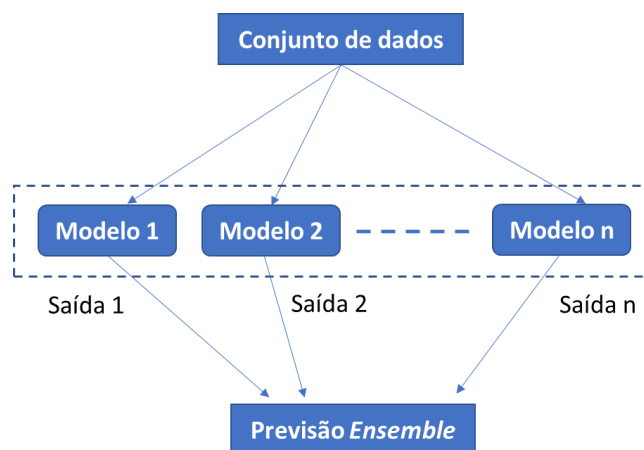
As formas disponíveis de combinações de previsões buscam detectar quais das técnicas podem ajudar na melhoria da acurácia. Diversos fatores influenciam na acurácia das previsões. Assim, técnicas diferentes podem contribuir capturando algum tipo de informação que venha a influenciar esses fatores (Werner; Ribeiro, 2006).

De acordo com Al-hajj, Assi e Fouad (2021), Baba *et al.* (2015) e Zhang e Ma (2012), os métodos do tipo *ensemble* podem ser divididos em duas classes:

- Sequencial: os modelos individuais são organizados sequencialmente, combinação comumente aplicada quando ocorre dependência entre os modelos individuais; e
- Paralela: que são organizados em uma estrutura paralela, tipo de técnica de conjunto comumente usada para lidar com a independência entre os modelos individuais de base do *ensemble*.

Na Figura 4.2 é apresentada uma estrutura paralela usada para a combinação de previsões individuais. Além dessa classificação, existe uma outra divisão: modelos *ensemble* heterogêneos (utilizam modelos de base de tipos diferentes) e *ensemble* homogêneos (utilizam modelos de base do mesmo tipo) (Zhang; Ma, 2012).

Figura 4.2 – *Ensemble* da classe paralela com  $n$  modelos individuais



Fonte: Adaptado de Al-hajj, Assi e Fouad (2021).

Três etapas precisam existir para a construção de um modelo *ensemble* eficaz: (1) definição dos dados a serem utilizados no treinamento dos modelos individuais (importância para a variabilidade); (2) modelos individuais a serem utilizados; e (3) tipo de combinação dos modelos individuais (Zhang; Ma, 2012).

Diferentes abordagens podem ser encontradas na literatura para desenvolver estratégias de previsão *ensemble* visando melhorar o desempenho de metodologias de previsão aplicadas individualmente. Uma abordagem de ajuste foi proposta em Abuella e Chowdhury (2019) para melhorar as metodologias de previsão combinadas e prever eventos de rampa com precisão. O aprendizado em conjunto foi aplicado como uma abordagem de pós-processamento para minimizar os resíduos das taxas de rampa previstas, combinando diferentes previsões e suas taxas de aumento.

Uma *complete ensemble empirical mode decomposition* (CEEMD) combinado com algoritmos de RF e *Kernel Ridge Regression* (KRR) foi desenvolvido em Ali *et al.* (2020) para projetar um modelo híbrido CEEMD-RF-KRR para prever chuva em escala mensal. O modelo híbrido proposto obteve melhor precisão de previsão de chuva, apresentando os melhores desempenhos em todos os locais analisados, em comparação aos modelos de referência, com valores máximos de coeficiente de correlação (R) (0,97–0,99), índice de *Willmott* (0,94–0,97), *Coefficiente de Nash-Sutcliffe* (0,94–0,97) e índice de Legates-McCabe (0,74–0,81).

Um método híbrido *Bayesian Ridge Regression* (BRR) - EEMD foi proposto em Yang e Yang (2020) para previsão de velocidade do vento a curto prazo. O EEMD foi usado para decompor séries complexas de velocidade do vento em várias subsequências relativamente mais suaves. Em seguida, cada subsequência foi realizada usando o BRR, sendo o valor de cada subsequência previsto por ele. Os valores de múltiplas subsequências foram então fundidos para formar os resultados de previsão da série temporal original. Segundo os autores, os valores previstos apresentaram maior acurácia em comparação com outros métodos de previsão.

Na área de prevenção, diagnóstico e tratamento de doenças humanas, um modelo de previsão denominado *Ensemble of KRR based MiRNA-Disease Association* (EKRRMDA) foi desenvolvido em Peng *et al.* (2020). Este modelo obteve características de microRNAs e doenças integrando a similaridade semântica da doença, a similaridade funcional dos microRNAs e a similaridade do *kernel* do perfil de interação gaussiana para doenças e microRNAs.

Um método de aprendizado de conjunto, integrando simultaneamente um modelo de preenchimento de matriz de baixa classificação e um modelo de *Ridge Regression* (RR) para prever a resposta de drogas anticancerígenas em linhagens de células cancerígenas, foi investigado em Liu *et al.* (2020c). O modelo foi aplicado a dois conjuntos de dados de referência, incluindo a *Cancer Cell Line Encyclopedia* e a *Genomics of Drug Sensitivity in Cancer*. Sequencialmente, foi realizada uma comparação entre o modelo de rede celular-droga integrada

de camada dupla e o modelo proposto. Dois tipos de estudos de caso verificaram a eficácia da proposta na previsão da resposta medicamentosa.

A combinação de três estratégias de aprendizado de conjunto também foi proposta (Livieris *et al.*, 2020): média de conjunto, ensacamento e empilhamento com modelos avançados de aprendizado profundo para prever os principais preços por hora de criptomoedas. Os modelos *ensemble* propostos foram avaliados utilizando modelos de aprendizado profundo de última geração como aprendizes de componentes, que eram compostos por combinações de LSTM, LSTM bidirecional e camadas convolucionais. A confiabilidade de cada modelo de previsão e a eficiência de suas previsões foram avaliadas examinando a autocorrelação dos erros. Segundo os autores, o *ensemble learning* e o *deep learning* podem ser eficientemente benéficos um para o outro para o desenvolvimento de modelos de previsão confiáveis.

Uma abordagem de Aprendizado por Reforço (AR) foi desenvolvida em Perepu *et al.* (2020) para atribuir e atualizar dinamicamente pesos de modelos de conjunto em diferentes instantes de tempo, dependendo da natureza dos dados e das previsões do modelo individual. Estudos de simulação em dados de séries temporais mostraram que a abordagem ponderada dinâmica usando AR aprende o peso melhor do que as abordagens existentes. A precisão do método foi comparada com uma abordagem existente de ajuste de RNA online quantitativamente por meio de valores de nRMSE.

O uso de métodos de pós-processamento EMOS e *ensemble copula acoplamento* (ECC) foi investigado em Worsnop, Scheuerer e Hamill (2020) para fornecer previsões probabilísticas calibradas localmente e espacialmente coerentes do índice *hot-dry-windy*. Cenários de previsão foram gerados por meio da variação do quantil ECC-Q equidistante, mantendo a coerência espacial e temporal reordenando as amostras das distribuições univariadas de acordo com os ranks do *ensemble* bruto. Foram utilizados dados de 20 anos sobre os Estados Unidos continentais. As habilidades de previsão foram quantificadas com a pontuação de probabilidade classificada contínua usando *benchmarks* de previsões brutas e climatológicas. Segundo os autores, o pós-processamento é benéfico durante todas as estações do ano para horizontes de previsão de até duas semanas.

Em Bremnes (2019), um *Constrained Quantile Regression Splines* (CQRS) para pós-processamento *ensemble* foi proposto e testado com dados de previsão de velocidade do vento do *European Centre for medium-range weather forecasts e Ensemble Prediction System* (ECMWF ENS) na Noruega. Uma comparação de CQRS versus um modelo de mistura de distribuições truncada e lognormal mostrou ligeiras melhorias gerais na pontuação de quantil,

confiabilidade e, até certo ponto, também nitidez. Para previsões de velocidade de vento forte, a pontuação do quantil foi melhorada em até 4,5%, dependendo do horizonte de tempo.

Na Tabela 4.1 são apresentadas as principais características dos artigos citados.

Tabela 4.1 - Resumo de abordagens corretivas usando previsão de séries temporais

<b>Referencia</b>	<b>Meta de Previsão</b>	<b>Técnicas Individuais ou dados envolvidos</b>	<b>Abordagem corretiva/Ensemble utilizada</b>	<b>Principais Considerações</b>
(Abuella; Chowdhury, 2019)	Eventos de rampa	Regressão Linear Multipla (RLM), MLP e SVR	Aprendizagem em conjunto	1. As classes de direção dos eventos de rampa são mais facilmente previstas do que as classes de magnitude dos eventos de rampa. 2. As previsões probabilísticas são mais valiosas com esquemas operacionais conservadores.
(Ali <i>et al.</i> , 2020)	Chuvas em escala mensal	RF e KRR	CEEMD	O modelo pode ser utilizado na gestão ótima dos recursos hídricos (seca, umidade, irradiação solar, culturas agrícolas).
(Yang; Yang, 2020)	Previsão de velocidade do vento a curto prazo	Dados Experimentais de Simulação Artificial e Dados Experimentais Sociais Reais	BRR-EEMD	Necessidade de ajustes e novas aplicações para aplicação no campo real.
(Peng <i>et al.</i> , 2020)	Características de microRNAs e doenças	Banco de dados de associações de miRNA-doença humana - HMDD V2.0	EKRRMDA	Aplicação de redução de dimensionalidade para eliminar ruídos. Cálculos de similaridade são realizados.
(Liu <i>et al.</i> , 2020c)	Previsão de resposta a medicamentos anticâncer	<i>Matrix completion</i> (MC) and RR	Aprendizagem de conjunto	A falta de respostas para alguns medicamentos limita o desempenho; estudos experimentais podem trazer melhorias.
(Livieris <i>et al.</i> , 2020)	Preço da criptomoeda na hora seguinte	LSTM e CNN	Aprendizagem em conjunto e DL	O custo computacional, a precisão e a confiabilidade do conjunto dependem da escolha da base e quantidade dos modelos.
(Perepu <i>et al.</i> , 2020)	Atribuir e atualizar pesos de modelos de conjunto	LSTM, MLP, RF	AR	Necessidade de estender o método proposto para modelagem de séries temporais multivariadas.
(Worsnop; Scheuerer; Hamill, 2020)	Previsões probabilísticas do índice hot-dry-windy	ECMWF e reanálise de dados de ERA-Interim	EMOS e ECC	Aplicado em tempo real, o gasto computacional seria menor e não exigiria validação cruzada.
(Bremnes, 2019)	Previsão de velocidade do vento	ECMWF ENS	CQRS	Aplicável, com pequenas modificações, a outras variáveis lógicas.

Fonte: Próprio autor.

A maioria dos artigos encontrados na literatura implementou metodologias combinadas e melhorou as previsões para apenas um parâmetro (eventos de rampa (Abuella; Chowdhury, 2019), irradiância solar (Lima *et al.*, 2020; Yang, 2020; Karasu; Altan, 2019), chuva (Ali *et al.*, 2020), velocidade do vento (Yang; Yang, 2020), geração eolioelétrica (Poncela-Blanco; Poncela, 2021). Neste contexto, a presente tese propõe implementar metodologias *ensemble* que visam à melhoria de previsões individualizadas aplicadas aos recursos solar e eólico, podendo ser uma ferramenta útil na redução dos impactos negativos que esses recursos intermitentes podem causar nos sistemas elétricos.

Este Capítulo apresentou uma contextualização teórica referente ao tema de previsão de conjunto (*ensemble*), apresentando diferentes trabalhos encontrados na literatura nos últimos anos. No próximo Capítulo serão apresentadas as metodologias individuais implementadas nesta Tese (denominadas MLP, CFBP, RBF e SOM), as duas metodologias de conjunto propostas visando à combinação das técnicas individuais (RRE e WD-RNA-RRE), e também o detalhamento do PrevTP (metodologia de conjunto utilizada para comparação dos resultados obtidos).

## 5 METODOLOGIA

Diversos trabalhos apresentam pesquisas baseadas em recursos solares e eólicos, aplicadas a diferentes soluções voltadas ao setor elétrico. Soluções baseadas em previsão eólica e solar para gerenciamento de energia em uma microrrede foram apresentadas em Heydari *et al.* (2019). O sistema de gerenciamento de energia ideal proposto utilizou previsões de recursos renováveis e consumo de energia.

De acordo com Hodge *et al.* (2018), os altos níveis de penetração de fontes renováveis em sistemas de energia devem aumentar concomitantemente com melhorias crescentes na previsão de energia renovável e armazenamento de eletricidade. Os autores desenvolveram uma metodologia para reduzir os impactos da alta inserção de fontes renováveis nas matrizes elétricas dos países com base em previsões solares e eólicas (individualizadas ou simultâneas), fazendo uma análise abrangente de como essas tecnologias alteram os sistemas elétricos e os custos operacionais.

A presente Tese realiza a previsão dos recursos eólico e solar para duas localidades: a) Petrolina – Brasil; e b) Algeciras – Espanha. Técnicas de previsibilidade baseadas em RNA são aplicadas e posteriormente integradas por duas técnicas *ensemble* e pelo PrevTP (implementados em *Matlab* na versão R2020a – licença acadêmica).

No presente capítulo são apresentados os dados de irradiância solar e de velocidade do vento, bem como as estruturas das RNA implementadas individualmente (técnicas heterogêneas) e a modelagem que envolve as três técnicas *ensemble* (RRE, WD-RNA-RRE e PrevTP) aplicadas visando previsões com melhor desempenho.

### 5.1 Obtenção de Dados

Os dados de Algeciras, Espanha, foram obtidos usando o *PV Geographical Information System* (PVGIS) da *European Commission / Institute for Energy and Transport* (IET) (*Photovoltaic Geographical Information System* 2020). Os dados anemométricos de Petrolina, Brasil, foram obtidos do banco de dados do Sistema de Organização Nacional de Dados Ambientais (SONDA). Esse sistema faz parte de um projeto do Instituto Nacional de Pesquisas Espaciais (INPE), para implantação de infraestrutura física e de recursos humanos para levantar e melhorar o banco de dados de recursos de energia solar e eólica no Brasil (SONDA, 2020).

As duas localidades têm condições climáticas diferentes: Petrolina é caracterizada por um clima semiárido; Algeciras tem um clima mediterrânico subtropical. Informações sobre torres de medição, períodos, latitude e longitude estão apresentadas na Tabela 5.1.

Os dados utilizados são valores horários, medidos a uma altura de 10 metros (Espanha) e de 50 metros (Brasil), para os dois recursos (solar/eólico) e para os dois locais. Os dados de velocidade do vento (m/s) contêm valores dia/noite; os dados de irradiância solar ( $W/m^2$ ) são filtrados para que sejam usados nas previsões apenas o período entre o nascer e o pôr do Sol.

Os dados de irradiância são filtrados com base no ângulo zenital solar ( $Theta_z$ ). Para grandes valores de  $Theta_z$  (próximo ao nascer e ao pôr do Sol), os valores intrínsecos de irradiância são baixos e, portanto, referem-se a momentos de pouca importância para o uso da fonte solar. Além disso, devido ao grande caminho óptico, os modelos tendem a falhar significativamente nesses momentos. Assim, é prática comum na literatura excluir valores de irradiância associados a momentos de alta  $Theta_z$  de todas as simulações, mantendo os dados quando o Sol está mais alto no céu.

Tabela 5.1 - Locais, recursos, períodos e latitude e longitude usados na previsão

Localização	Recurso	Período	Número de dados utilizados	Latitude	Longitude
<b>Petrolina - Brasil</b>	Velocidade do vento (m/s)	2007-2010	35.064	09° 04' 08" S	40° 19' 11" O
	Irradiância solar ( $W/m^2$ )	2013 - 2016	18.030		
<b>Algeciras - Espanha</b>	Velocidade do vento (m/s)	2007-2010	35.064	36° 08' 12.9" N	05° 27' 12" O
	Irradiância solar ( $W/m^2$ )	2007-2010	16.316		

Fonte: Próprio autor.

## 5.2 Técnicas Individuais

As quatro técnicas utilizadas para a previsão da velocidade do vento e da irradiância solar nos locais mencionados são: *Backpropagation Multilayer Perceptron* (MLP), *Radial Basis Function* (RBF), *Cascade Forward Back Propagation* (CFBP) e *Self-Organizing Map* (SOM). Essas quatro técnicas são escolhidas com base em uma revisão da literatura e na constatação de aplicações consolidadas dessas metodologias para a previsão de diferentes séries temporais. A MLP para previsão de recursos solares é usada em Ali Jallal *et al.* (2020). Uma modelagem de



uma matriz FV usando o modelo CFBP é encontrada em Ameen *et al.* (2015). CFBP e SOM também são aplicados em Carvalho e Carneiro (2021) para estimar o futuro nexso água-energia. O RBF é implementado para a previsão da geração FV em Hu *et al.* (2018) e do recurso solar em Jiang *et al.* (2015). Uma RBF com memória distribuída é usada em Sideratos e Hatzigiorgiou (2020) para prever a eletricidade produzida por fontes eólicas e solares. Uma metodologia baseada em modelagem RBF e MLP pode ser encontrada em Silva *et al.* (2022). Uma RNA do tipo SOM é implementada em combinação com outros modelos em Lan *et al.* (2018) e Dong *et al.* (2015) para a previsão de recurso solar e aplicada individualmente como preditor em Farias *et al.* (2013).


Para as quatro aplicações individuais, os dados foram normalizados por meio da Equação 5.1, deixando os dados entre 0 e 1, para que possam ser aplicados às funções de ativação adequadamente.

$$X_n = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (5.1)$$

em que  $X_n$  é o valor normalizado,  $X_i$  é o valor observado,  $X_{min}$  é o menor valor e  $X_{max}$  é o maior valor do conjunto de dados.

Nas quatro técnicas, foi utilizada a validação cruzada, em que o conjunto de dados foi particionado em subconjuntos mutuamente exclusivos. 70% dos dados foram utilizados para estimar os parâmetros do modelo (dados de treinamento e validação), enquanto 30% foram utilizados para testar o modelo. O esquema de validação utilizado é apresentado na Figura 5.1.

Figura 5.1 – Esquema para validação cruzada na fase de treinamento



Fonte: Próprio autor.

Na Tabela 5.2 são apresentadas as médias de RMSE obtidas pelos métodos individuais aplicados à previsão do recurso solar no Brasil e na Espanha. Esse resultado refere-se à melhor

combinação de parâmetros, com diferentes configurações para cada validação (diferentes entradas, neurônios e taxas de aprendizagem) e melhores erros obtidos na aplicação de validação cruzada por 10 vezes (*3-folds*).

Tabela 5.2 – Média dos erros na validação cruzada – recurso solar

<b>Aplicação</b>	<b>Média do RMSE (W/m<sup>2</sup>)</b>	<b>nRMSE = Média do RMSE (W/m<sup>2</sup>)/ Média da Série de dados (W/m<sup>2</sup>)*</b>
MLP – Recurso Solar - Espanha	57,381	0,085
CFBP – Recurso Solar - Espanha	31,412	0,046
RBF – Recurso Solar – Espanha	45,738	0,069
SOM – Recurso Solar – Espanha	89,351	0,134
MLP – Recurso Solar – Brasil	89,351	0,209
CFBP – Recurso Solar – Brasil	69,323	0,162
RBF – Recurso Solar – Brasil	100,058	0,236
SOM – Recurso Solar – Brasil	69,325	0,162

Fonte: Próprio autor. \* Média da Série do Recurso Solar na Espanha = 666,094 W/m e Média da Série do Recurso Solar no Brasil = 426,891 W/m<sup>2</sup> (ambas, desconsiderando os períodos noturnos)

Tabela 5.3 – Média dos erros na validação cruzada – recurso eólico

<b>Aplicação</b>	<b>Média do RMSE (m/s)</b>	<b>nRMSE = Média do RMSE (m/s)/Média da Série de dados (m/s)*</b>
MLP – Recurso Eólico - Espanha	0,453	0,088
CFBP – Recurso Eólico - Espanha	0,493	0,096
RBF – Recurso Eólico – Espanha	0,575	0,112
SOM – Recurso Eólico – Espanha	0,553	0,107
MLP – Recurso Eólico – Brasil	0,910	0,178
CFBP – Recurso Eólico – Brasil	0,399	0,078
RBF – Recurso Eólico – Brasil	0,515	0,101
SOM – Recurso Eólico – Brasil	0,615	0,120

Fonte: Próprio autor. \* Média da Série do Recurso Eólico na Espanha = 5,15 m/s e Média da Série do Recurso Eólico no Brasil = 5,11 m/s

### 5.2.1 *Multilayer Perceptron (MLP)*

A MLP é utilizada como uma estratégia alternativa para resolver problemas não lineares, que RNA como *perceptron* de camada única e *adaline* não poderiam resolver (Braga, Carvalho;

Ludermir, 2007). Essas não-linearidades são incorporadas aos modelos neurais por meio das funções de ativação (não lineares) de cada neurônio e da composição de sua estrutura em camadas sucessivas.

A MLP é uma rede neural *perceptron* com pelo menos uma camada intermediária e alta conectividade, utilizando funções de ativação não lineares e diferenciáveis (Rocha *et al.*, 2019). As aplicações para previsão de recursos eólicos e solares no Brasil e na Espanha possuem as seguintes configurações de entradas:

- a) Vetor de entrada da previsão de recursos eólicos na Espanha (com 6 neurônios ocultos na camada intermediária):

$$[V(t-6), V(t-5), V(t-4), V(t-3), V(t-2), V(t-1), V(t)];$$

- b) Vetor de entrada da previsão de recursos solares na Espanha (com 5 neurônios ocultos na camada intermediária):


$$[I(t-6), I(t-5), I(t-4), I(t-3), I(t-2), I(t-1), I(t)];$$

- c) Vetor de entrada de previsão de recursos solares no Brasil (com 4 neurônios ocultos na camada intermediária):

$$[I(t-8), I(t-7), I(t-6), I(t-5), I(t-4), I(t-3), I(t-2), I(t-1), I(t)];$$

O vetor de entrada definido para a previsão de recursos eólicos no Brasil está representado na Figura 5.2. Para aplicações de previsão de recursos eólicos, a saída é  $V(t+1)$ , e em aplicações de previsão de recursos solares a saída é  $I(t+1)$ .

Figura 5.2 - Arquitetura MLP para previsão de recursos eólicos em Petrolina, Brasil



Fonte: Próprio autor.

A função de ativação usada tanto para a camada de neurônios ocultos quanto para a camada de saída é o sigmoide logística representada pela Equação 5.2.

$$y_j = \frac{1}{1 + \exp(-u_j)} \quad (5.2)$$

em que  $y_j$  é a saída do neurônio e  $u_j$  é a soma ponderada de todas as entradas.

O algoritmo utilizado para o treinamento das RNA MLP foi o "*backpropagation*", que é uma generalização do algoritmo de treinamento "regra delta" da rede Adaline. O MLP usa o gradiente descendente para estimar o erro nas camadas intermediárias, bem como o efeito que esses erros têm no erro da camada de saída. O erro da camada de saída é calculado e, posteriormente, retropropagado para as camadas anteriores, permitindo o ajuste dos pesos proporcionalmente aos valores das conexões entre as camadas, por meio da Equação 5.3.

$$w_{ij}^m(t+1) = w_{ij}^m(t) - \alpha \cdot \delta_i^m \cdot y_j^{m-1} \quad (5.3)$$

em que  $w_{ij}^m(t+1)$  é o peso atualizado,  $w_{ij}^m(t)$  é o peso na iteração,  $\alpha$  é a taxa de aprendizado da RNA,  $\delta_i^m$  é a sensibilidade,  $y_j^{m-1}$  é a saída da camada anterior, e  $i$  e  $j$  identificam os neurônios da camada posterior e anterior da conexão, respectivamente.

Taxas de aprendizado de 0,25 e 0,15 foram usadas em redes ANN-MLP aplicadas à previsão de velocidade do vento na Espanha e no Brasil, respectivamente. Nas previsões de irradiância solar, foram utilizadas taxas de aprendizado de 0,35 e 0,45 para Espanha e Brasil, respectivamente.

O algoritmo básico do modelo MLP para previsão segue as etapas descritas a seguir:

1. Leitura e preparação dos dados para treinamento, validação e teste;
2. Inicialização aleatória dos pesos e bias;
3. Processamento dos dados da entrada até a saída;
4. Cálculos dos erros de previsão;
5. Retropropagação;
6. Teste da RNA.


### 5.2.2 Radial Basis Function (RBF)

As redes RBF usam a distância entre seus vetores de entrada para ativar neurônios na camada intermediária, com funções de base radial como funções de ativação. Em geral, as redes RBF possuem apenas uma camada intermediária. A saída da RBF é calculada por uma combinação linear entre as ativações da camada intermediária e os pesos que interligam as duas

camadas. Cada neurônio intermediário RBF define um hiperelipsóide no espaço dos padrões de entrada, que são aproximadores locais (Haykin, 1999).

O treinamento da RBF tem duas etapas. Na primeira, estima-se o número de funções de base radial e seus parâmetros (centro e dispersão) são definidos por aprendizado não supervisionado. Na segunda, os pesos dos neurônios de saída são ajustados. Na presente aplicação, quatro redes RBF foram treinadas e aplicadas para prever dados de velocidade do vento e irradiância solar no horizonte horário no Brasil e na Espanha. A estrutura da RBF aplicada para a previsão de irradiância solar na Espanha é mostrada na Figura 5.3.

Figura 5.3 - Arquitetura RBF utilizada para previsão de irradiância solar em Algeciras, Espanha



Fonte: Próprio autor.

Os vetores de entrada das outras três aplicações são:

- a) Vetor de entrada da previsão de recursos eólicos na Espanha (com 7 neurônios ocultos na camada intermediária):

$$[V(t-4), V(t-3), V(t-2), V(t-1), V(t)];$$

- b) Vetor de entrada de previsão de recursos solares no Brasil (com 5 neurônios ocultos na camada intermediária):

$$[I(t-5), I(t-4), I(t-3), I(t-2), I(t-1), I(t)];$$

- c) Vetor de entrada de previsão de recursos eólicos no Brasil (com 4 neurônios ocultos na camada intermediária):

$$[V(t-6), V(t-5), V(t-4), V(t-3), V(t-2), V(t-1), V(t)];$$

A camada de saída em todas as aplicações é composta por um único neurônio. Nas previsões do recurso eólico é o valor da velocidade  $V(t+1)$  e nas previsões do recurso solar é o

valor da irradiância solar  $I(t+1)$ . As Equações 5.4 e 5.5 são consideradas usando a função Gaussiana.

$$\varphi = \exp\left(-\frac{r^2}{2\sigma^2}\right) \quad (5.4)$$

$$r = \|x - t\| \quad (5.5)$$

onde  $\varphi$  é a saída de cada neurônio da camada oculta,  $r$  é a diferença entre a entrada  $x$  e o centro  $t$ , e  $\sigma$  é a medida do espalhamento da curva.

A saída RBF é formada por um único neurônio linear, que é calculado usando a Equação 5.6. A soma de cada saída dos neurônios da camada oculta é ponderada por seus respectivos pesos.

$$y = \sum w_j \varphi_j \quad (5.6)$$

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

O treinamento da RBF é dividido em dois estágios: inicialmente, o reposicionamento dos centros foi feito por meio de *k-means* (Lima, 2020). Em seguida, foi realizado o ajuste dos demais parâmetros livres de RBF. Neste caso, o ajuste dos pesos foi feito pela Equação 5.7.

$$w_{ij}^m(t+1) = w_{ij}^m(t) - \alpha \cdot e_{ij}^m(t) \cdot \varphi \quad (5.7)$$

em que  $w_{ij}^m(t+1)$  é o peso atualizado,  $w_{ij}^m(t)$  é o peso na iteração,  $\alpha$  é a taxa de aprendizado da RNA,  $\delta_i^m$  é a sensibilidade,  $e_{ij}^m(t)$  é o erro na iteração, e  $i$  e  $j$  identificam os neurônios da camada posterior e anterior da conexão, respectivamente.

Taxas de aprendizado de 0,35 (0,55) e 0,25 (0,65) foram usadas em redes RBF aplicadas à previsão de velocidade do vento (previsões de irradiância solar) na Espanha e no Brasil, respectivamente.

O algoritmo básico do modelo RBF para previsão segue as seguintes etapas:

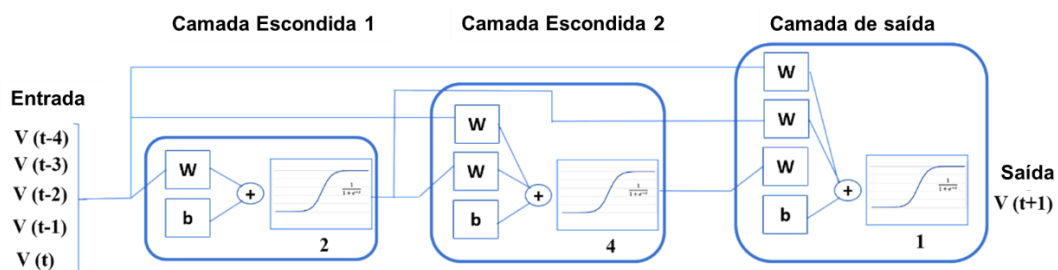
1. Leitura e preparação dos dados para treinamento, validação e teste;
2. Estágio 1: Inicialização aleatória dos centros e a aplicação do *k-means* para ajuste dos centros e definição do espalhamento por normalização;
3. Estágio 2: Processamento das camadas oculta e de saída, cálculos de erros e ajustes de pesos;
4. Teste da RNA.

### 5.2.3 Cascade Forward Back Propagation (CFBP)

O CFBP é uma combinação de redes do tipo MLP, apresentando uma estrutura onde a entrada é conectada a todas as camadas da rede, aumentando as oportunidades de correção mais precisa de erros no processo de retropropagação aumentando a probabilidade da precisão da previsão (Đozic; Gvozdenac, 2019).

Como as MLP, as CFBP utilizam o *backpropagation* para treinamento. Quatro CFBP foram aplicadas para prever recursos eólicos e solares no Brasil e na Espanha, usando as mesmas taxas de aprendizado aplicadas em redes MLP simplificadas. O algoritmo de retropropagação para atualizar os pesos ( $W$ ) é descrito na Equação 5.3. Funções sigmóides (Equação 5.2) foram aplicadas para criar conexões não lineares entre neurônios e entre camadas. Uma das arquiteturas utilizadas para previsão de recurso eólico no Brasil é mostrada na Figura 5.4. Os parâmetros para a previsão do recurso eólico na Espanha são detalhados a seguir, como também os parâmetros utilizados na previsão do recurso solar no Brasil e Espanha.

Figura 5.4 - Arquitetura CFBP para previsão de recurso eólico em Petrolina, Brasil



Fonte: Próprio autor.

- a) Vetor de entrada da previsão de recurso eólico na Espanha (3 neurônios ocultos na primeira camada, 4 neurônios ocultos na segunda camada):

$$[V(t-5), V(t-4), V(t-3), V(t-2), V(t-1), V(t)];$$

- b) Vetor de entrada da previsão de recurso solar na Espanha (5 neurônios ocultos na primeira camada e 4 neurônios ocultos na segunda camada):

$$[I(t-5), I(t-4), I(t-3), I(t-2), I(t-1), I(t)];$$

- c) Vetor de entrada de previsão de recurso solar no Brasil (3 neurônios ocultos na primeira camada e 2 neurônios ocultos na segunda camada):

$$[I(t-6), I(t-5), I(t-4), I(t-3), I(t-2), I(t-1), I(t)];$$

Para as aplicações de previsão de recursos eólicos, a saída é velocidade do vento na hora seguinte  $V(t+1)$ , e nas aplicações de previsão de recursos solares a saída é a irradiância solar na hora seguinte  $I(t+1)$ . O algoritmo básico da CFBP é o mesmo da MLP, com a diferença que todas as camadas recebem os dados da entrada (Đozic; Gvozdenac, 2019).

#### 5.2.4 Self-Organizing Map (SOM)

A RNA do tipo SOM tem como objetivo principal o agrupamento de vetores com características semelhantes em uma mesma classe (neurônio vencedor) ou em classes semelhantes (neurônios vizinhos) (Haykin, 1999). Sua arquitetura contém uma camada de entrada multidimensional e uma camada de saída que pode ser unidimensional ou bidimensional. Na camada de saída ou camada competitiva, os neurônios competem e apenas um deles é considerado o vencedor, i.e., a classe mais adequada para um dado vetor de entrada  $x$ . Cada elemento do vetor de entrada está conectado a todos os elementos da camada de saída. A força das conexões é medida por meio de pesos  $w_{ij}$  entre os neurônios de entrada  $j$  e os neurônios da camada de saída  $i$ . Na etapa de treinamento, as distâncias euclidianas entre o vetor de entrada e os pesos conectados a cada um dos neurônios de saída são calculadas usando a Equação 5.8.

$$DI_i = \sqrt{\sum_{j=1}^J (x_j - w_{ij})^2} ; \text{ for } i=1,2,\dots,M \quad (5.8)$$

em que  $x_j$  é o  $j$ -ésimo componente do vetor de entrada  $\mathbf{x}$ ,  $J$  é a dimensão do vetor de entrada  $x$  e  $M$  é o número total de neurônios na camada de saída.

O neurônio de saída  $i$  que obtém a menor distância euclidiana do vetor de entrada é o neurônio vencedor. Os pesos conectados a este neurônio  $i^*$  e neurônios dentro de um raio de vizinhança  $V_{i^*}$  são então atualizados pela regra de Kohonen (Beale; Hagan; Demuth, 2012), de acordo com a Equação 5.9.

$$W_{ij}(n) = W_{ij}(n-1) + \alpha \cdot [x_j(n) - W_{ij}(n-1)]; \quad (5.9)$$

for  $i \in V_{i^*}$  e  $j=1,2,\dots,J$

em que  $\alpha$  é a taxa de aprendizagem e  $n$  é o índice que representa a sequência de apresentação das amostras à rede.

Os pesos atribuídos ao neurônio vencedor e seus vizinhos são forçados a se mover em direção ao vetor de entrada apresentado à rede seguindo a regra de *Kohonen*, fazendo com que a distância euclidiana se torne menor e permitindo a classificação de vetores semelhantes. Para



determinar a vizinhança, as distâncias entre os neurônios na camada de saída podem ser definidas de várias maneiras (Beale; Hagan; Demuth, 2012). Na presente aplicação, é utilizada a função do tipo bolha de base quadrada (Braga, Carvalho; Ludermir, 2007).

O primeiro treinamento é a fase de ordenação e o segundo treinamento é a fase de ajuste. A etapa de ordenação é limitada a 60% das iterações e o raio da vizinhança é iniciado com uma certa distância que diminui até atingir o valor de uma unidade. Assim, os pesos dos neurônios são dispostos no espaço de entrada de maneira consistente com suas posições. A fase de ajuste dura o restante do número de iterações. Nessa etapa, como o raio da vizinhança é igual a um, apenas os pesos do neurônio vencedor são atualizados. Espera-se que os pesos mudem de forma relativamente uniforme no espaço de entrada, mantendo a topologia definida na fase de ordenação (Beale; Hagan; Demuth, 2012). Taxas de aprendizagem SOM de 0,15, 0,25, 0,55 e 0,75 foram usadas para as previsões de vento no Brasil e Espanha e para as previsões solares no Brasil e Espanha, respectivamente.

SOM treinado pode ser usado como ferramenta de previsão (Farias *et al.*, 2013). Para isso, deve-se considerar o vetor de entrada com a ausência da variável a ser prevista, seguindo os seguintes passos:

- Passo 1: Realizar o cálculo das distâncias euclidianas entre os vetores de entrada e os pesos ligados ao neurônio de saída, desconsiderando o elemento  $j$  a ser previsto. Isso pode ser feito incluindo uma variável booleana  $m_j$ , como mostrado na Equação 5.10. A variável  $m_j$  é utilizada para incluir ( $m_j = 1$ ) ou excluir ( $m_j = 0$ ) a contribuição de um dado elemento  $j$  do vetor de entrada para o cálculo das distâncias euclidianas.

$$DI_i = \sqrt{\sum_{j=1}^J m_j (x_j - w_{ij})^2} ; \text{ for } i=1,2,\dots, M \quad (5.10)$$

- Passo 2: Determinar o neurônio vencedor com base na menor distância euclidiana.
- Passo 3: Usar o peso do neurônio vencedor anexado ao elemento ausente  $j$  do vetor de entrada como a previsão.

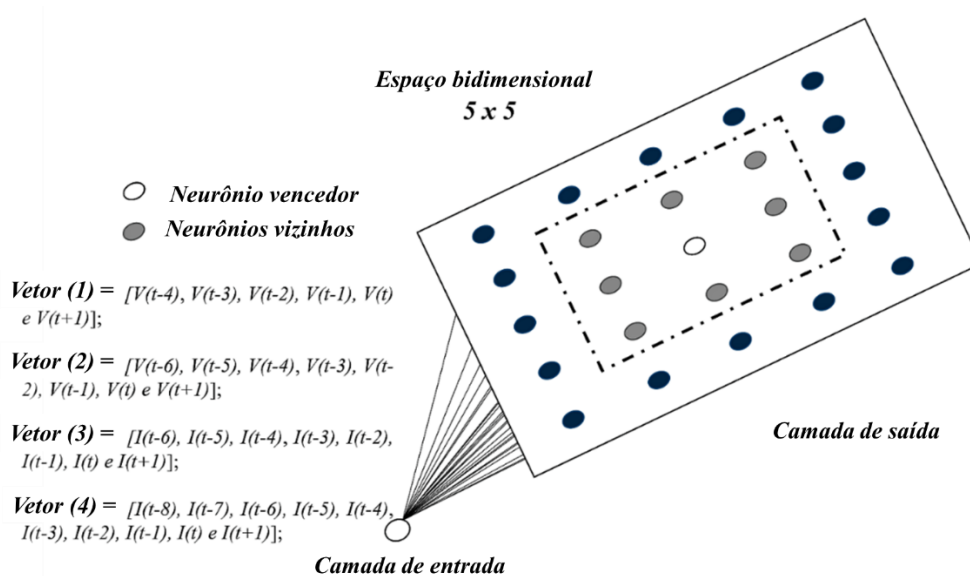
Para as previsões de recursos eólicos, foram utilizados vetores de camada de entrada com 5 neurônios (quatro atrasos no tempo) e 7 neurônios (6 atrasos no tempo) para o Brasil e Espanha, respectivamente. Esses vetores foram representados pelos vetores (1) e (2) na Figura 5.5, onde  $V(t+1)$  é a saída. Para as previsões dos recursos solares, as camadas de entrada tinham

7 neurônios (seis atrasos no tempo) e 9 neurônios (8 atrasos no tempo) para Espanha e Brasil, respectivamente, representados pelos vetores (3) e (4) na Figura 5.5, onde a saída é  $I(t+1)$ . Foi utilizada uma camada de saída bidimensional composta por 25 neurônios. Na Figura 5.5 é apresentada a estrutura do SOM, destacando um neurônio vencedor e seus vizinhos. O treinamento do modelo ocorre no modo sequencial.

O algoritmo básico do modelo SOM para previsão segue as seguintes etapas:

1. Leitura e preparação dos dados a serem utilizados para treinamento, validação e teste;
2. Inicialização aleatória dos pesos;
3. Competição: Cada padrão de entrada é apresentado a RNA, calcula-se a resposta dos neurônios da grade de saída e é definido o neurônio vencedor;
4. Cooperação: o neurônio vencedor define uma vizinhança topológica;
5. Adaptação Sináptica: onde os neurônios aprendem em relação ao padrão de entrada apresentado (por meio da atualização dos pesos do neurônio vencedor e seus vizinhos ficando mais próximos do padrão de entrada);
6. Uso do modelo SOM treinado como ferramenta preditiva; e
7. Teste da RNA.

Figura 5.5 - Arquitetura da SOM para previsão de irradiância solar e velocidade do vento em Algeciras (Espanha) (vetores 2 e 3, respectivamente) e Petrolina (Brasil) (vetores 1 e 4, respectivamente)



Fonte: Próprio autor.

### 5.3 Metodologias *Ensemble* Utilizadas para Integração das Previsões Individuais

Um modelo *ensemble* é definido como uma abordagem que se baseia em dividir para conquistar e visa melhorar a precisão de preditores aplicados individualmente. Os modelos preditivos realizam individualmente tarefas específicas, e quando suas previsões são combinadas, um novo resultado com maior precisão é obtido (Mendes-Moreira *et al.*, 2012; Stefenon *et al.*, 2022).

Considerando o estado da arte apresentado no Capítulo 3 e a constatação de que metodologias de integração/conjunto e modelagens híbridas que combinam um ou mais modelos individuais têm trazido benefícios nas diferentes aplicações preditivas de recursos intermitentes, a presente Tese propõe o desenvolvimento de duas diferentes metodologias de conjunto.

A primeira metodologia utilizada é um método de aprendizagem *ensemble* baseado em *Ridge Regression* (L2 penalizado), definido *Ridge Regression Ensemble (RRE)*, que integra metodologias consolidadas de previsão eólica e solar aplicadas a dois locais com diferentes latitudes e perfis climáticos.

A segunda metodologia proposta é uma abordagem híbrida que visa a aplicação da *Wavelet Decomposition (WD)* para pré-processamento e pós-processamento dos dados brutos de cada localidade, o uso de quatro metodologias preditivas individuais baseadas em AM e do RRE. Para a avaliação das metodologias propostas, é utilizada uma metodologia de integração que usa uma adaptação da teoria do portfólio (PrevTP) (Lima, 2020).

#### 5.3.1 PrevTP

Uma adaptação da TP, proposta inicialmente em Lima (2020), denominada PrevTP, é aplicada para integrar as previsões obtidas por modelos preditivos aplicados aos recursos solares e eólicos no Brasil e na Espanha. Na teoria do TP, quanto maior a quantidade de ativos, menor será o risco diversificável. Desse modo, a melhor forma de atingir uma rentabilidade elevada com um risco menor, é diversificando os investimentos em todas as classes de ativos. O PrevTP visa o mesmo entendimento, em que a diversificação de preditores vem a melhorar o desempenho geral da previsão para diferentes séries temporais.

Em seu primeiro uso, o objetivo da TP era maximizar um retorno financeiro, a qualquer risco, por meio da diversificação de títulos ou investimentos que não estivessem positivamente

correlacionados (Markowitz, 1992; Markowitz, 1956; Renner, 2010). De acordo com Devaraj *et al.* (2021), as técnicas de previsão de recursos intermitentes podem melhorar o planejamento, operação e gestão de redes elétricas. A metodologia PrevTP pode integrar e melhorar os resultados das previsões individuais.

O risco de previsão pode ser definido como a dificuldade que uma técnica específica ou uma combinação de técnicas têm na obtenção do resultado da previsão. Quanto menor o risco, maior a possibilidade de a previsão acertar seu resultado. Uma aplicação do TP foi encontrada em Dunlop (2004). O modelo de precificação de ativos de capital é usado para entender se é possível possuir um único grande parque eólico ou um portfólio de parques eólicos menores. A conclusão alcançada foi que o risco de produção pode ser reduzido em até 30% mantendo um portfólio de parques eólicos em vez de um único grande parque eólico. No entanto, o autor destacou que isso depende da correlação entre os parques e que depende da localização.

De acordo com Lima (2020), o PrevTP é dividido nas seguintes etapas: a) coleta e tratamento dos dados; b) previsão da velocidade do vento usando as metodologias individuais; c) estudo dos erros e riscos de previsão; d) processamento de dados dos erros e riscos de previsão pelo PrevTP; e) definição final da ponderação dos ativos pelo PrevTP; e f) verificação do erro de previsão usando as metodologias integradas pela metodologia proposta em comparação com os ativos individuais.

Durante a definição dos pesos de integração, ou seja, durante o treinamento PrevTP, cada uma das técnicas de entrada (MLP, CFBP, RBF e SOM) é comparada com as velocidades do vento e irradiâncias solares observadas. Com isso, é possível entender a precisão e variabilidade das técnicas de previsão em relação à velocidade do vento e à irradiância solar nas duas localidades.

O percentual de erros é calculado comparando as RNA aplicadas individualmente e utilizando o fator de impacto definido nas Equações 5.11 e 5.12. Esses erros relacionados às previsões de velocidade do vento e irradiância solar podem ocorrer em diferentes horários do dia em que o recurso está disponível no local (Speth, 2012).

$$E_{pp} = \frac{(D_p - D_m)100}{D_m} F_i \quad (5.11)$$

$$F_i = \frac{D_m}{M_r} \quad (5.12)$$

em que  $D_p$  são os dados previstos,  $D_m$  são os dados observados,  $M_r$  o maior recurso e  $F_i$  é o fator de impacto.

O fator de impacto é usado para nivelar os erros de previsão levando-se em consideração a amplitude de disponibilidade de recurso, reduzindo as discrepâncias devido à subestimação ou superestimação desses erros (Lima, 2020).

A Equação 5.13 define o cálculo da variabilidade dos ativos por meio de correlação.

$$p_{xy} = \frac{\text{Cov}(y, x)}{\sigma_x \cdot \sigma_y} \quad (5.13)$$

em que  $p_{xy}$  é a correlação entre  $x$  e  $y$  (ativos),  $\text{Cov}(y, x)$  é a covariância entre  $x$  e  $y$ ,  $\sigma_x$  são o desvio padrão de  $x$ , e  $\sigma_y$  é o desvio padrão de  $y$ .


A covariância entre  $x$  e  $y$  é obtida por meio da Equação 5.14.

$$\text{Cov}(y, x) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n} \quad (5.14)$$

em que  $x_i$  são os valores dos ativos de  $x$ ,  $\bar{x}$  é o valor médio do ativo  $x$ ,  $y_i$  são os valores dos ativos  $y$ ,  $\bar{y}$  é o valor médio do ativo  $y$ , e  $n$  representa a quantidade de valores dos ativos.

O risco da carteira pode ser determinado pelo cálculo do desvio padrão, que revela a probabilidade de determinado resultado. Para definir o percentual de cada ativo e com isso reduzir os erros de previsão, é necessário construir um gráfico de Fronteira Eficiente. Esses limites são linhas formadas por diferentes proporções de ativos em uma carteira, representando graficamente como um determinado retorno pode promover o menor risco possível. Na Figura 5.6 é mostrada a situação hipotética de uma aplicação diversificada utilizando os ativos A e B.

Figura 5.6 – Exemplo de fronteira eficiente entre ativos A e B



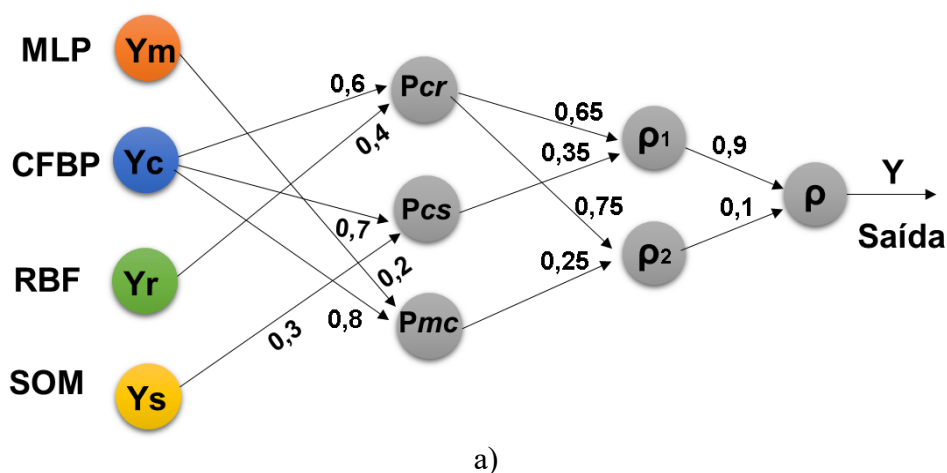
Fonte: Lima (2020).


Um valor absoluto para risco aceitável não pode ser definido. Nesse caso, o risco, medido pelo desvio padrão, é inerente ao processo de previsão. O desvio padrão (risco) sempre existirá e o PrevTP sempre busca reduzir o risco diversificável combinando os previsores.

Nas Figura 5.7 - 5.10 são apresentadas as estruturas completas e simplificadas da PrevTP utilizadas para a integração das técnicas individuais para o recurso eólico do Brasil, recurso eólico da Espanha, recurso solar no Brasil e recurso solar da Espanha, respectivamente.

Observa-se nas arquiteturas da Figura 5.7, que a integração das previsões do recurso eólico no Brasil ocorreu por meio das conexões  $P_{cr}$  (CFBP e RBF),  $P_{cs}$  (CFBP e SOM) e  $P_{mc}$  (MLP e CFBP). Sequencialmente,  $\rho_1$  e  $\rho_2$  representam as duas melhores conexões (menores erros de previsão) entre  $P_{cr}$ ,  $P_{cs}$  e  $P_{mc}$  e  $\rho$  exibe o valor de previsão PrevTP. A representação simplificada é utilizada após o treinamento e seus pesos finais interligarem as metodologias aplicadas individualmente. A contribuição de cada modelo individual na estrutura simplificada do PrevTP é obtida a partir da soma das verossimilhanças dos caminhos para a saída  $Y$ , por meio das conexões  $P_{cr}$ ,  $P_{cs}$  e  $P_{mc}$ ,  $\rho_1$  e  $\rho_2$ . Na aplicação com o recurso eólico no Brasil as contribuições de cada modelo individual foi de 0,005 para o  $Y_m$ , 0,6365 para o  $Y_c$ , 0,264 para o  $Y_r$  e de 0,095 para o  $Y_s$ . Um detalhamento dos riscos e erros calculados durante o treinamento da PrevTP está apresentado na Tabela 5.4.

Figura 5.7 – Arquiteturas: a) Estrutura da PrevTP; b) Estrutura simplificada da PrevTP. Ambas aplicadas a integração de previsões de velocidade do vento no Brasil





b)

Fonte: Próprio autor.

Os erros e o risco são reduzidos após a integração em cada conexão (Tabela 5.4). Na Figura 5.7a é ilustrada a contribuição significativa (60% do CFBP e 40% do RBF) na conexão Pcr (a de menor risco e MAPE), que foi a mais utilizada na estrutura PrevTP otimizada. Os modelos CFBP e RBF foram escolhidos com alta contribuição no resultado, pois, apresentam os melhores MAPE e riscos. O modelo MLP apresentou alto MAPE e alto risco (maiores entre os preditores individuais), sendo o modelo que a estrutura adaptativa menos utilizou para a obtenção do resultado (0,005), pois poderia reduzir a previsibilidade do modelo PrevTP.

Tabela 5.4 - Resumo de erros e riscos calculados em todas as etapas da aplicação ao recurso eólico no Brasil

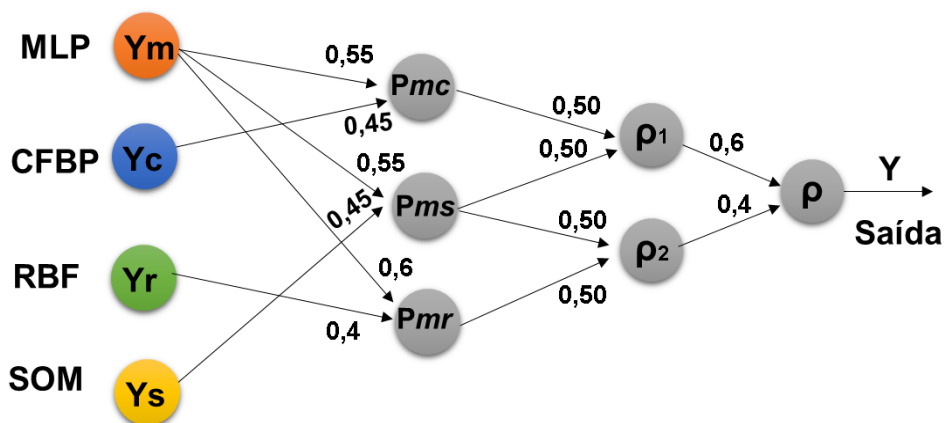
Modelo/Combinação	MAE	MAPE	RISCO
Ym – MLP	0,874	6,263	8,199
Yc – CFBP	0,616	<b>3,163</b>	<b>4,100</b>
Yr - RBF	1,108	<b>3,784</b>	<b>4,938</b>
Ys – SOM	0,538	5,025	6,563
<i>Pcr</i>	0,812	<b>2,523</b>	<b>3,155</b>
<i>Pcs</i>	0,592	2,743	3,488
<i>Pmc</i>	0,667	2,912	3,684
$\rho 1$	0,735	<b>2,390</b>	<b>2,985</b>
$\rho 2$	0,777	2,467	3,078
$\rho$ (PrevTP)	0,740	2,389	2,984

Fonte: Próprio autor.

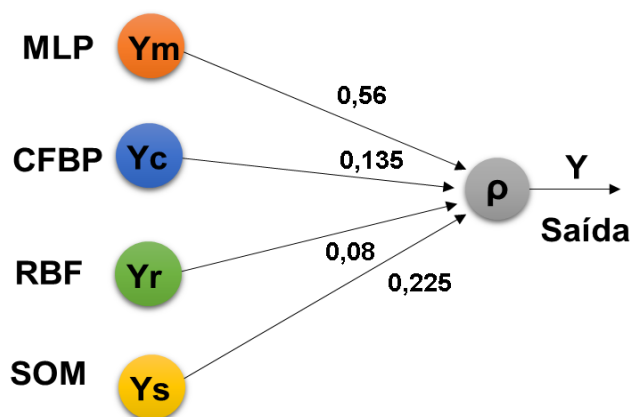
A partir das arquiteturas apresentadas na Figura 5.8, observa-se que a integração das previsões do recurso eólico na Espanha ocorreu por meio das conexões *Pmc* (MLP e CFBP), *Pms* (MLP e SOM) e *Pmr* (MLP e RBF).  $\rho 1$  e  $\rho 2$  representam as duas melhores conexões (menores erros e riscos de previsão) entre *Pmc*, *Pms* e *Pmr* e  $\rho$  é a previsão do PrevTP. Na

aplicação com o recurso eólico na Espanha as contribuições de cada modelo individual no PrevTP foi de 0,56 para o  $Y_m$ , 0,135  $Y_c$ , 0,08 para o  $Y_r$  e de 0,225 para o  $Y_s$ .

Figura 5.8 – Arquiteturas: a) Estrutura da PrevTP; b) Estrutura simplificada da PrevTP. Ambas aplicadas a integração de previsões de velocidade do vento na Espanha



a)



b)

Fonte: Próprio autor.

O detalhamento dos riscos e erros calculados durante o treinamento da PrevTP aplicado ao recurso eólico na Espanha está apresentado na Tabela 5.5. Os erros e o risco são reduzidos durante o treinamento e ajuste da estrutura do PrevTP. Na Figura 5.8a é ilustrada a contribuição significativa (em torno de 50% da MLP) em todas as conexões  $P_{mc}$ ,  $P_{ms}$  e  $P_{mr}$ , que foram utilizadas de forma similar na obtenção da saída final, tendo as três conexões erros e riscos similares. O modelo MLP foi escolhido com alta contribuição no resultado (mais de 50%) pois, apresentou os melhores MAPE e risco.



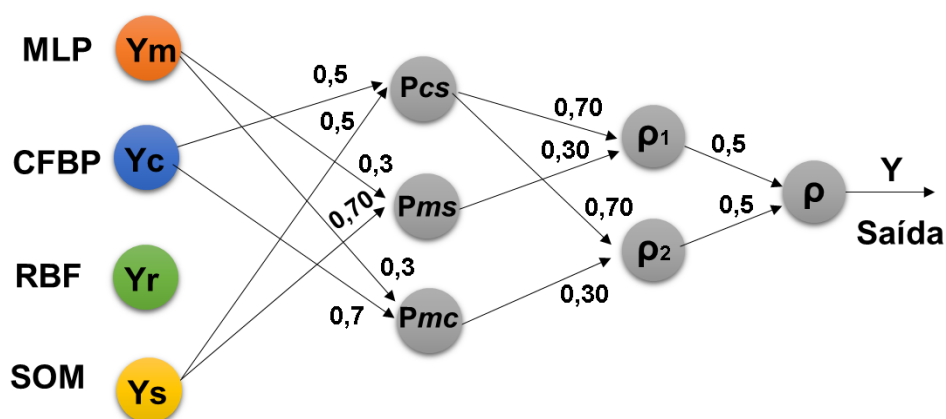
Tabela 5.5 - Resumo de erros e riscos calculados em todas as etapas da aplicação ao recurso eólico na Espanha

Modelo/Combinação	MAE	MAPE	RISCO
$Y_m$ – MLP	0,052	<b>1,558</b>	<b>2,464</b>
$Y_c$ – CFBP	0,720	1,793	2,750
$Y_r$ - RBF	0,278	2,107	2,995
$Y_s$ – SOM	0,422	1,996	2,848
$P_{mr}$	0,143	<b>1,361</b>	<b>1,895</b>
$P_{ms}$	0,161	<b>1,331</b>	<b>1,877</b>
$P_{mc}$	0,353	<b>1,314</b>	<b>1,840</b>
$\rho_1$	0,095	1,150	1,630
$\rho_2$	0,009	1,173	1,668
$\rho$ (PrevTP)	0,053	1,111	1,590


Fonte: Próprio autor.

A integração das previsões do recurso solar no Brasil, como apresentada nas arquiteturas da Figura 5.9, ocorreu por meio das conexões  $P_{cs}$  (CFBP e SOM),  $P_{ms}$  (MLP e SOM) e  $P_{mc}$  (MLP e CFBP).  $\rho_1$  e  $\rho_2$  são as duas melhores conexões (menores erros e riscos de previsão) entre  $P_{cs}$ ,  $P_{ms}$  e  $P_{mc}$  e o  $\rho$  é a previsão final do PrevTP. Na aplicação com o recurso solar no Brasil as contribuições de cada modelo individual no PrevTP foram de 0,09 para o  $Y_m$ , 0,455 para o  $Y_c$ , 0 para o  $Y_r$  (preditor eliminado durante o treinamento) e de 0,455 para o  $Y_s$ .

Figura 5.9 – Arquiteturas: a) Estrutura da PrevTP; b) Estrutura simplificada da PrevTP. Ambas aplicadas a integração de previsões de irradiância solar no Brasil



a)



Fonte: Próprio autor.

Os riscos e erros calculados durante o treinamento da PrevTP, em cada camada e por conexão, aplicado ao recurso solar no Brasil estão apresentados na Tabela 5.6. Observa-se que os riscos e erros (nesse caso reduzidos a menos de 50% dos valores iniciais) vão sendo reduzidos até chegar na previsão final do PrevTP, demonstrando que a estrutura adaptativa consegue obter o melhor de cada conexão visando melhorar o resultado. Na Figura 5.9a é ilustrada a contribuição significativa (50% das CFBP e SOM) na conexão  $P_{cs}$  (menor erro e menor risco entre as conexões de sua camada), que chega com 70% nas conexões  $\rho_1$  e  $\rho_1$ , utilizadas em igual porcentagem (50% cada) no resultado  $Y$ .

Tabela 5.6 - Resumo de erros e riscos calculados em todas as etapas da aplicação ao recurso solar no Brasil

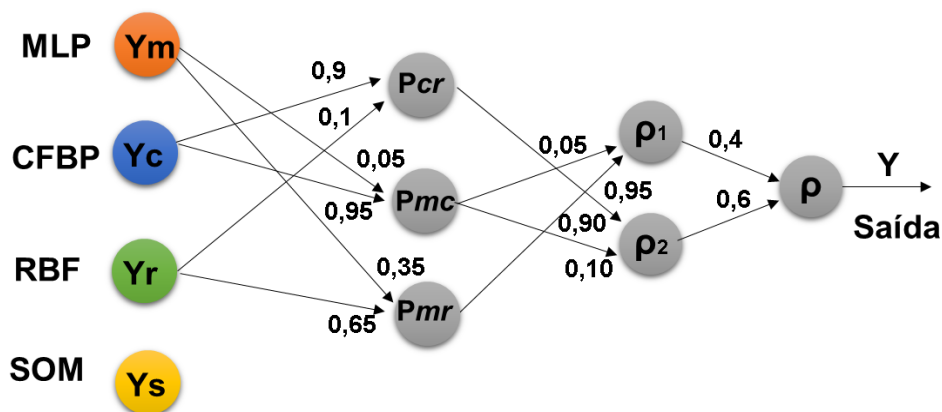
Modelo/Combinação	MAE	MAPE	RISCO
$Y_m$ – MLP	0,757	6,999	10,077
$Y_c$ – CFBP	0,428	<b>4,705</b>	<b>6,718</b>
$Y_r$ – RBF	2,602	7,628	10,290
$Y_s$ – SOM	0,029	<b>4,698</b>	<b>6,718</b>
$P_{cs}$	0,228	<b>3,512</b>	<b>4,796</b>
$P_{ms}$	0,206	4,084	5,582
$P_{mc}$	0,073	4,088	5,578
$\rho_1$	0,097	<b>3,342</b>	<b>4,561</b>
$\rho_2$	0,181	<b>3,342</b>	<b>4,560</b>
$\rho$ (PrevTP)	0,140	3,287	4,454

Fonte: Próprio autor.


Na integração das previsões do recurso solar na Espanha, apresentada na Figura 5.10, foram utilizadas as conexões  $P_{cr}$  (CFBP e RBF),  $P_{mc}$  (MLP e CFBP) e  $P_{mr}$  (MLP e RBF).  $\rho_1$

e  $\rho_2$  sendo as duas melhores conexões (menores erros e riscos de previsão) entre  $P_{cr}$ ,  $P_{mc}$  e  $P_{mr}$  e o  $\rho$  a previsão final do PrevTP. Na aplicação com o recurso solar na Espanha as contribuições de cada modelo individual no PrevTP foi de 0,137 para o  $Y_m$ , 0,562  $Y_c$ , 0,301 para o  $Y_r$  e de 0 para o  $Y_s$  (preditor eliminado durante o treinamento).

Figura 5.10 – Arquiteturas: a) Estrutura da PrevTP; b) Estrutura simplificada da PrevTP. Ambas aplicadas a integração de previsões de irradiância solar na Espanha



a)



b)

Fonte: Próprio autor.

Um detalhamento dos riscos e erros calculados durante o treinamento da PrevTP, em cada camada e por conexão, aplicado ao recurso solar na Espanha está apresentado na Tabela 5.7.

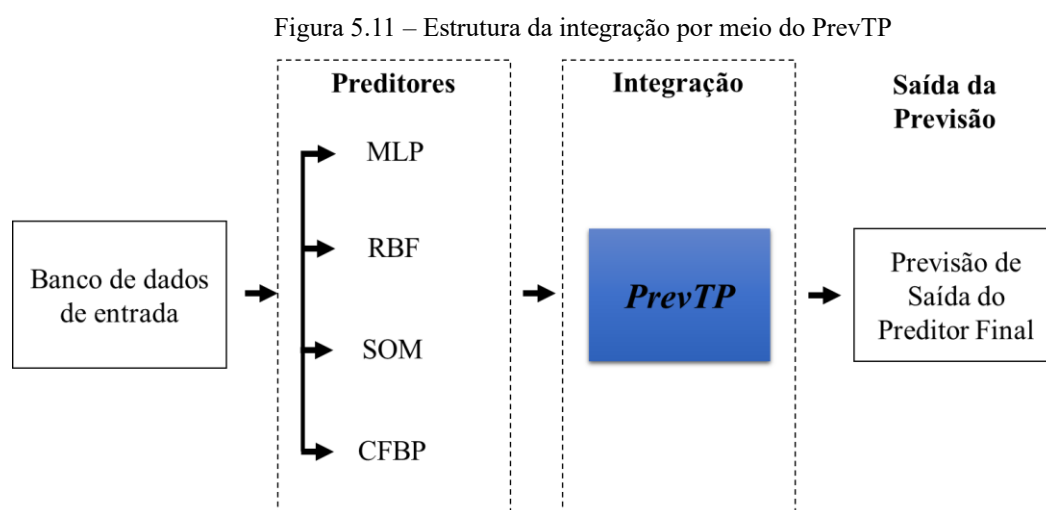
Tabela 5.7 - Resumo de erros e riscos calculados em todas as etapas da aplicação ao recurso solar na Espanha

<b>Modelo/Combinação</b>	<b>MAE</b>	<b>MAPE</b>	<b>RISCO</b>
Y <sub>m</sub> – MLP	1,511	4,489	6,184
Y <sub>c</sub> – CFBP	2,493	<b>2,493</b>	<b>1,408</b>
Y <sub>r</sub> - RBF	0,570	2,966	4,653
Y <sub>s</sub> – SOM	<b>8,641</b>	<b>8,641</b>	4,366
<i>Pcr</i>	2,186	<b>2,211</b>	<b>1,355</b>
<i>Pmc</i>	2,443	<b>2,449</b>	<b>1,369</b>
<i>Pmr</i>	0,157	2,604	3.731
$\rho_1$	2,086	<b>2,125</b>	<b>1,352</b>
$\rho_2$	2,216	<b>2,241</b>	<b>1.336</b>
$\rho$ (PrevTP)	2,164	2,190	1,322

Fonte: Próprio autor.

Os erros e o risco vão sendo reduzidos durante a integração, conforme Tabela 5.7. Na Figura 5.10a é ilustrada a contribuição significativa (em torno de 90% do CFBP) nas conexões *Pcr* e *Pmc* (as de menores riscos e MAPE), que foram as mais utilizadas na estrutura PrevTP final. O modelo CFBP foi escolhido com alta participação (mais de 56%) por apresentar os melhores MAPE e riscos. O modelo SOM foi eliminado durante o treinamento por apresentar altos MAPE e MAE.

As etapas gerais de processamento dos dados, sejam eólicos ou solares e independente do local aplicado, são mostradas na Figura 5.11.



Fonte: Adaptado de Lima *et al.* (2020) e Carneiro *et al.* (2022).

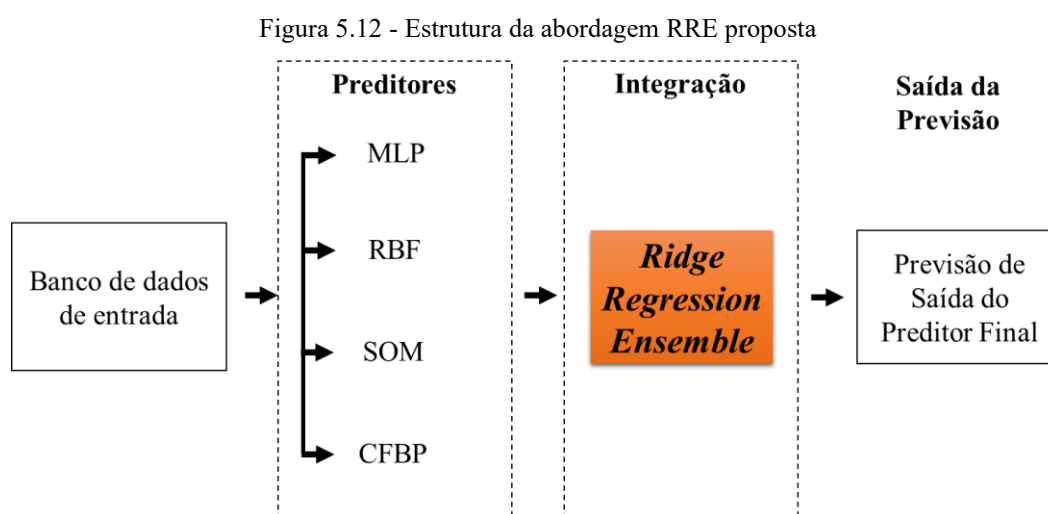
A PrevTP realiza a integração paralela de metodologias de previsão, para os diferentes recursos intermitentes e localidades. Com a topologia formada a partir do treinamento do PrevTP, a estrutura de processamento dos dados pode ser resumida da seguinte forma: entrada

com as janelas de informações sobre recurso intermitente utilizado em cada técnica (MLP, CFBP, RBF e SOM), processamento das previsões pelas referidas RNA e aplicação das integrações com ponderações feitas a partir das fronteiras eficientes encontradas pelo PrevTP.

As etapas são as seguintes: a) coleta de dados de velocidade do vento e irradiância solar; b) treinamento e aplicação dos previsores MLP, CFBP, RBF e SOM e o cálculo e análise de seus respectivos erros de previsão; c) produção de fronteiras eficientes que são utilizadas para integração de técnicas por meio da PrevTP; e d) aplicação de pesos; e demonstração de resultados.

### 5.3.2 Ridge Regression Ensemble (RRE)

Os modelos *ensemble* no paradigma AM consistem essencialmente em misturar modelos padrões para obtenção de melhores resultados em relação aos separados (Zhang; Ma, 2012). Alguns modelos são agrupados em essência, como RF e *Gradient Boosted Regression Tree*. Por outro lado, também é uma abordagem comum combinar diferentes modelos para chegar a um resultado, usando uma média simples ou ponderada. Existem muitos exemplos recentes na literatura, que vão desde a aplicação direta de métodos de *ensemble* (Tazim *et al.*, 2020; Sunil *et al.*, 2021) até a combinação de resultados obtidos separadamente por diferentes modelos (Soumyashree *et al.*, 2021). Na Figura 5.12 é apresentada a ideia principal do procedimento de *ensemble* dessa aplicação. Cada modelo gera independentemente seu próprio resultado, que é combinado com os resultados de outros métodos de AM para gerar a saída final do conjunto. No presente estudo, este procedimento é realizado por uma combinação linear dos métodos AM.



Fonte: Próprio autor.

Uma forma de agregar os resultados dos métodos é utilizando sistemas de regressão linear, principalmente os que fornecem seleção automática de variáveis (James *et al.*, 2013). Em Konstantinov e Utkin (2021) é aplicado o LASSO (Tibshirani, 1996) para encontrar os pesos de uma abordagem de AM combinada. Os autores indicam que a *Ridge Regression* (Hoerl; Kennard, 1970) pode ser usada para a mesma tarefa. Com este objetivo, uma *ridge regression* é usada para combinar os resultados de modelos de AM, visando a obtenção de uma melhor saída.

Ao contrário do LASSO, a regressão *ridge* raramente remove completamente um preditor, que, neste trabalho, é a saída de cada método específico. Essa opção foi escolhida uma vez que o número de modelos testados não produz um grande número de preditores. Assim, optou-se por deixar todas as contribuições possíveis. A regressão de cume encontra os coeficientes de regressão linear adicionando um termo de penalidade L2 ( $\lambda \sum_{j=1}^p \beta_j^2$ ) e relacionado à soma dos coeficientes (Equação 5.15), impondo assim um equilíbrio entre o erro de previsão e o impacto de cada preditor.

$$\arg \min_{\lambda} \left[ \sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij})^2 + \lambda \sum_{j=1}^p \beta_j^2 \right] \quad (5.15)$$

Nesta Equação, o primeiro termo somatório visa minimizar o erro entre os valores de treinamento e os preditos, enquanto o segundo termo somatório adiciona ao procedimento de minimização o peso de cada preditor (neste caso, as saídas do modelo), tendendo a reduzir os valores (e importância) de um modelo específico que apresenta piores resultados. Essa abordagem costuma superar o desempenho PrevTP (Lima *et al.*, 2020), pois enquanto a última melhora o desempenho por uma grade de pesos pré-especificados, a primeira encontra esses valores por algoritmos de otimização. Nesse sentido, após o procedimento de sintonia do hiperparâmetro  $\lambda$ , são determinadas as contribuições  $\beta_j$  de cada modelo, originando assim um novo valor predito (*ensembled*).

É bem conhecido na comunidade de AM, nomeadamente pelo teorema "*no free lunch*" (Wolpert; Macready, 1997), que nenhum modelo pode ser reconhecido como o melhor num sentido global. Ou seja, se hipoteticamente todos os cenários possíveis pudessem ser avaliados para diferentes modelos, na média eles teriam desempenho semelhante. Sob esta premissa, o uso da abordagem *ensemble* permite aproveitar o método que melhor se adapta a cada cenário específico (solar/vento, localização, etc.), uma vez que não se poderia afirmar a priori qual

método é o melhor para aquela situação. Essa possibilidade justifica a escolha da avaliação *ensemble*, uma vez que tenderá para o método de melhor desempenho para cada caso estudado.

O RRE é desenvolvido seguindo as seguintes etapas:

1. Os parâmetros  $\lambda$  são determinados pelo usuário;
2. Os coeficientes betas ( $\beta$ ) são determinados por meio do conjunto de dados e dos parâmetros de penalidade (Equação 5.16);

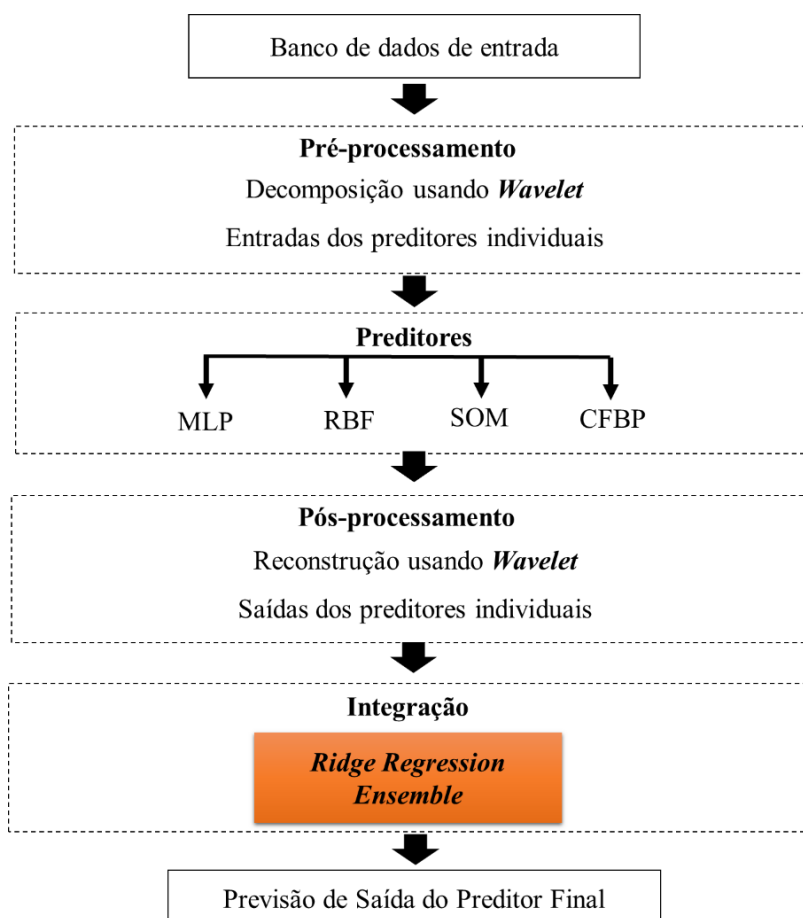
$$\hat{\beta}^{ridge} = (X^T X + \lambda I)^{-1} X^T Y \quad 5.16$$

3. O  $\lambda$  que fornece o menor RMSE na validação cruzada é escolhido como o parâmetro de configuração; e
4. No final, o modelo é reajustado com o  $\lambda$  selecionado e as previsões do RRE são obtidas.

### ***5.3.3 Modelo híbrido que combina Decomposição Wavelet, Aprendizado de Máquina e Ridge Regression Ensemble***

Considerando o desempenho satisfatório da aplicação RRE e visando obter resultados ainda melhores por meio dessa modelagem *ensemble*, a presente Tese propõe o uso de WT para pré e pós-tratamento dos dados brutos visando empregá-los nas metodologias individuais de previsão e, obtendo melhores resultados dessas metodologias, aplicar o RRE novamente, obtendo resultados ainda melhores e contribuindo para a obtenção de modelos preditivos que possam ser aplicados para os recursos solares e eólicos no Brasil e na Espanha. Não foi encontrado na literatura a combinação de WD, RNA e RRE nas diversas modelagens híbridas estudadas. No entanto, as modelagens híbridas visam obter o melhor de cada modelo usado na combinação, o que é proposto na presente tese. Na Figura 5.13 é apresentada a estrutura híbrida proposta.

A metodologia híbrida proposta é dividida em quatro principais etapas: a) pré-tratamento dos dados brutos: WD; b) Aplicação dos dados decompostos na previsão eólica e solar a ser realizada por meio dos modelos de AM; c) pós-tratamento: reconstrução dos componentes previstos pelos modelos individuais via transformada inversa *Wavelet*; d) Combinação dos resultados dos modelos individuais por meio do modelo RRE.

Figura 5.13 - Estrutura da abordagem híbrida proposta (*WD* – *RNA* – *RRE*)

Fonte: Próprio autor.

A decomposição *Wavelet* (WD) vem com a proposta de reduzir as oscilações acentuadas, picos e diferentes tipos de dados não estacionários que as séries contenham. As séries de velocidade do vento e de irradiância solar apresentam essas variabilidades devido às mudanças inesperadas que ocorrem nas condições meteorológicas.

A WD permite que uma série temporal seja ampliada escalando e esticando uma função WT predefinida sobre todas as observações, conseguindo extrair mudanças abruptas de curto e longo prazo. As WT pegam o sinal original e o decompõem em componentes detalhados (D) (filtros passa-alta) e componentes aproximados (filtro passa-baixa) (Risse, 2019).

De acordo com Rasa *et al.*, (2017), a WT pode ser discreta ou contínua e podem ser aplicadas para decompor séries de dados em diferentes componentes com um comportamento mais estável e com menores variações em comparação com as séries originais. A decomposição aumenta a capacidade de treinamento dos preditores individuais. Na aplicação de Rasa *et al.*, (2017), a WD decompõe séries de geração solar e demanda e consegue obter melhorias, em



termos de nRMSE, na previsão de demanda, sendo 17% em previsões diárias e 20% nas previsões semanais.

Diversas pesquisas obtiveram resultados satisfatórios por meio do uso da decomposição via transformada de WT. Em Zhu *et al.* (2017) uma série de índice de céu claro é decomposta pela tecnologia WT para obter quatro subséries com frequências diferentes; combinada com PCA e RNA para a previsão de mapas diários de irradiação solar em Li *et al.* (2020); na modelagem híbrida proposta em Monjoly *et al.* (2017) onde a decomposição WT é combinada aos modelos EMD e EEMD; no modelo híbrido proposto em Chaudhary e Rizwan (2018) a WT é combinada a RNA para a previsão da geração FV. Um pré-processamento de séries do recurso eólico por meio da WD pode ser encontrado em Zhang *et al.* (2020) (a metodologia híbrida combina WD com NAR, NARX e SVM). Li *et al.* (2020a) também realiza pré-processamento por meio de WD, no entanto, aplicado a dados de geração eólica (combinando WD com SVM).

De acordo com Zhu *et al.* (2017), a WD é eficaz na análise de informações locais do sinal tanto no domínio do tempo como no da frequência. O sinal apresentado é decomposto em diferentes séries de frequências (alta e baixa frequência), lidando bem com séries não estacionárias (Daubechies, 1990). Utilizaremos a transformação WT discreta para decompor as séries de irradiância solar (W/m<sup>2</sup>) e velocidade do vento (m/s), para as duas localidades, visando a obtenção de séries mais relativamente estáveis, a fim de melhorar a precisão das previsões dos modelos de AM aplicados individualmente.

As *Wavelets* são apresentadas em forma de blocos com propriedades de translação e dilatação em uma função  $\Psi_{a,b}(t)$ , definida na Equação 5.17 (Melo, 2018).

$$\Psi_{a,b}(t) = |a|^{-\frac{1}{2}} \times \Psi\left(\frac{2^{\frac{a}{2}} - b}{a}\right) \quad 5.17$$

em que é  $|a|^{-\frac{1}{2}}$  o fator de normalização,  $a$  é índice de escala e  $b$  é o índice de translação.  $a, b \in R$ , com  $a > 0$ .

Para dados discretos, é considerado o  $a = 2^{-j}$  e  $b = k \times 2^{-j}$  (Melo, 2018). As principais Equações WT discreta são: o sinal da WT mãe ( $\Psi_{j,k}(t)$ ) e a função de escala  $\phi_{j,k}(t)$ , definidos nas Equações 5.18 e 5.19 (Li; Wang; Goel, 2015).

$$\Psi_{j,k}(t) = 2^{\frac{j}{2}} \times \Psi(2^{\frac{j}{2}} t - k) \quad 5.18$$

$$\phi_{j,k}(t) = 2^{\frac{j}{2}} \times \phi(2^{\frac{j}{2}} t - k) \quad 5.19$$

Em que  $j$  e  $k$  apresentam o parâmetro de escala e o de localização temporal, respectivamente.

Combinando as Equações 5.17 e 5.18 com os coeficientes aproximados (A) e detalhados (D) obtidos é possível expressar o sinal  $x(t)$  por meio da Equação 5.20 (Uzinski; Oliveira; Abreu, 2020).

$$x(t) = \sum_k A^{j_0} [k] \phi_{j,k}(t) + \sum_{j \leq j_0} \sum_k D^j [k] \Psi_{j,k}(t) \quad 5.20$$

em que  $j_0$  é o coeficiente de pré-escalamento. O primeiro somatório apresenta a tendência (componentes de baixa frequência) e o segundo apresenta os componentes de alta frequência. A série  $x(t)$  é composta pelo coeficiente de aproximação no último nível  $j_0$  e pelos coeficientes de detalhes em todos os níveis  $j$ .

De acordo com Uzinski, Oliveira e Abreu (2020) os coeficientes de aproximação  $A^j[k]$  e de detalhes  $D^j[k]$  são definidos como apresentado nas Equações 5.21 e 5.22.

$$A^j[k] = \langle x(t), \phi_{j,k}(t) \rangle \quad 5.21$$

$$D^j[k] = \langle x(t), \psi_{j,k}(t) \rangle \quad 5.22$$

Vários trabalhos têm implementado a família de WT de *Daubechies*, proposta por Ingrid *Daubechies* (Daubechies, 1988), usadas amplamente na análise de sinais para extrair características desejáveis em diferentes sinais e a ordem mais utilizada é para  $N=4$ . (Mandal *et al.*, 2013; Zhu *et al.*, 2017; Rasa *et al.*, 2017; Lee; Vale, 2020).

Na Tabela 5.8 são apresentados os valores de RMSE obtidos pelo modelo híbrido nos diferentes testes efetuados para a escolha do tipo de *Wavelet* e da quantidade de níveis. Para os dados do recurso eólico, nas duas localidades, o tipo de *Wavelet* com melhor desempenho foi a db4, da família *Daubechies*, com 6 níveis. Já relacionados aos dados solares no Brasil e na Espanha as *Wavelets* utilizadas foram a db10 e db2, respectivamente (com 5 níveis de decomposição). As séries decompostas referentes os dados eólicos e solares nas duas localidades estão apresentados no Anexo B.

Algumas metodologias individuais combinadas com WT são encontradas na literatura: para previsão do recurso solar combinada a MLP (Teixeira Júnior *et al.*, 2012; Saraiva *et al.*, 2014); para previsão do recurso eólico por meio de WT-RNA (De Christo *et al.*, 2016).

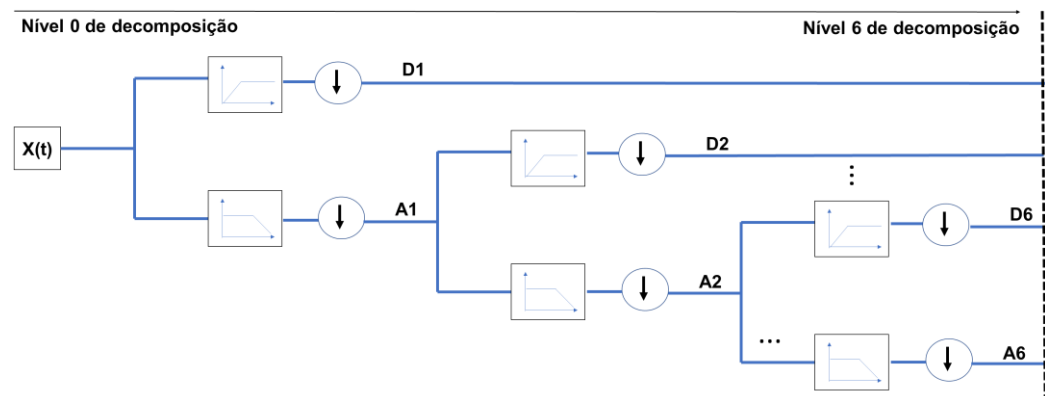
Tabela 5.8 - Testes desenvolvidos para a escolha do tipo de *Wavelet* e da quantidade de níveis a ser considerada nas aplicações aos dados eólicos e solares nas duas localidades

<i>Daubechies/níveis</i>		RMSE obtido na saída do WD-RNA-RRE			
		Recurso Eólico na Espanha (m/s)	Recurso Eólico no Brasil (m/s)	Recurso Solar na Espanha (W/m <sup>2</sup> )	Recurso Solar no Brasil (W/m <sup>2</sup> )
db2	3	0,415	0,435	25,147	37,114
	4	0,398	0,412	22,451	36,298
	<b>5</b>	0,410	0,384	<b>19,127</b>	28,369
	6	0,416	0,372	19,985	28,074
db4	3	0,422	0,432	23,874	36,154
	4	0,418	0,391	19,936	32,114
	5	0,395	0,367	20,114	29,458
	<b>6</b>	<b>0,370</b>	<b>0,354</b>	20,587	29,997
db6	3	0,418	0,440	28,117	45,124
	4	0,405	0,383	26,258	36,479
	5	0,429	0,376	23,784	29,587
	6	0,399	0,398	22,102	30,255
db8	3	0,432	0,410	27,321	47,501
	4	0,423	0,426	25,481	43,269
	5	0,392	0,398	20,369	40,159
	6	0,396	0,374	23,574	39,113
db10	3	0,423	0,417	26,513	48,265
	4	0,434	0,387	24,587	35,269
	<b>5</b>	0,386	0,377	22,146	<b>27,471</b>
	6	0,390	0,369	22,036	27,984

Fonte: Próprio autor.

Na Figura 5.14 é mostrado um exemplo de como é decomposta a série  $x(t)$  para as aplicações referentes ao recurso eólico nas duas localidades; o componente de aproximação, nesse caso  $A_6$ , representa a tendência, os componentes  $D_2$ ,  $D_3$ ,  $D_4$ ,  $D_5$ ,  $D_6$  representam sazonalidades e o  $D_1$  apresenta os ruídos, considerando que é composta pelos valores de mais alta frequência (Uzinski; Oliveira; Abreu, 2020).

Figura 5.14 – a) Esquema de decomposição (6 níveis); b) Previsão por modelos individuais; c) Reconstrução; e d) aplicação do *ensemble* proposto aos dados de vento nas duas localidades



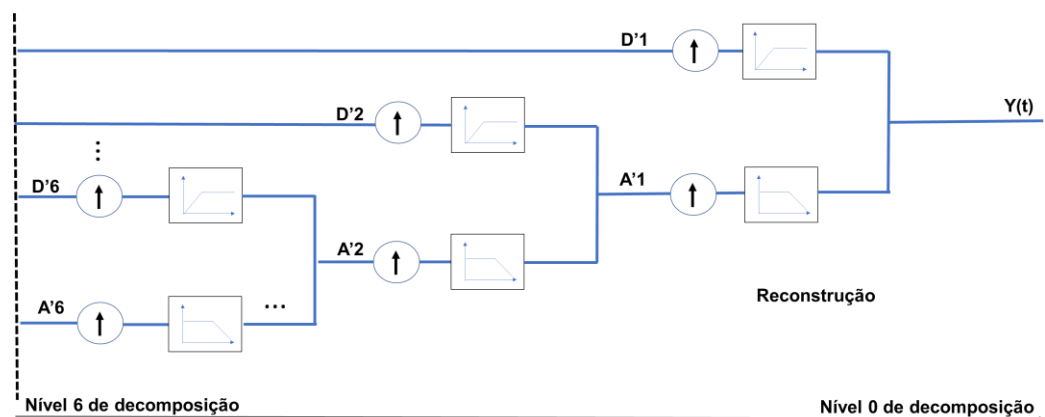
a)

$A6, D1, D2, D3, D4, D5$  e  $D6$




$A'6, D'1, D'2, D'3, D'4, D'5$  e  $D'6$

b)



c)

$Y(t) - Y_m, Y_c, Y_r$  e  $Y_s$



$Y_{RRE}(t)$

d)

Fonte: Decomposição e reconstrução adaptados de Mallat (1989) e Uzinski, Oliveira e Abreu (2020).

O WD-RNA-RRE é desenvolvido seguindo as etapas descritas abaixo:

1. O sinal inicial (para as séries do recurso eólico e solar nas duas localidades, aplicados um de cada vez) é decomposto por meio da WT e são gerados diferentes componentes incluindo os de aproximação e de detalhes;
2. Os componentes obtidos por meio da WD são aplicados nas RNA e suas previsões são geradas;
3. Os resultados obtidos pelas RNA são reconstruídos obtendo as previsões dos modelos individuais; e
4. Com as previsões dos modelos individuais, por recurso e para cada localidade, o modelo RRE é aplicado com o objetivo de combinar os resultados obtendo o resultado do conjunto (ensemble), seguindo os passos descritos abaixo:
  - Os parâmetros  $\lambda$  são determinados pelo usuário;
  - Os coeficientes beta ( $\beta$ ) são determinados por meio do conjunto de dados e dos parâmetros de penalidade (Equação 5.16);
  - O  $\lambda$  que fornece o menor RMSE na validação cruzada é escolhido como o parâmetro de configuração; e
  - No final, o modelo é reajustado com o  $\lambda$  selecionado e as previsões do RRE são obtidas.

#### 5.4 Análise dos Resultados

Os resultados obtidos pelos modelos aplicados individualmente, pelo PrevTP e pelo modelo RRE foram avaliados usando as métricas descritas nas Equações 5.23, 5.24, 5.25 e 5.26.

$$RMSE = \sqrt{\frac{1}{N} \sum_{I=1}^N (X_{previsto} - X_{observado})^2} \quad (5.23)$$

$$MAE = \frac{1}{N} \sum_{I=1}^N |X_{previsto} - X_{observado}| \quad (5.24)$$

$$R = \frac{\sum_i^N (X_{observado_i} - X_{media_observados}) \cdot (X_{previsto_i} - X_{media_previstos})}{\sqrt{\sum_i^N (X_{observado_i} - X_{media_observados})^2 \cdot \sum_i^N (X_{previsto_i} - X_{media_previstos})^2}} \quad (5.25)$$

$$MAPE = \frac{1}{N} \sum_{l=1}^N \frac{|X_{previsto} - X_{observado}|}{X_{observado}} \times 100\% \quad (5.26)$$

Em que  $X_{previsto}$  é o valor previsto,  $X_{observado}$  é o valor observado ou real,  $X_{media\_observados}$  é a média dos valores observados,  $X_{media\_previstos}$  é a média dos valores previstos.

Também são utilizados gráficos com uma janela de tempo de 4 dias escolhidos aleatoriamente do conjunto de dados, que relacionam os valores previstos e observados para os quatro modelos aplicados individualmente, no PrevTP e para o modelo RRE, considerando aplicações no Brasil e Espanha e os recursos intermitentes sob análise, *Boxplots* com erros absolutos e gráficos de correlação.

Neste Capítulo, foram detalhadas as diferentes metodologias implementadas nesta Tese. O detalhamento contemplou desde a coleta e o tratamento dos dados do Brasil e da Espanha, as técnicas individuais de AM e suas respectivas fundamentações matemáticas. Foi realizado também o detalhamento das técnicas de conjunto (RRE, WD-RNA-RRE e PrevTP). No próximo Capítulo, serão apresentados Gráficos, Tabelas e *Boxplots* com os resultados das previsões dos recursos solar e eólico, para as duas localidades, obtidos, tanto pelas técnicas individuais, quanto pelas suas respectivas combinações realizadas pelas três técnicas de conjunto.

## 6 RESULTADOS E DISCUSSÕES

Como mencionado anteriormente, a presente Tese tem como objetivo o processamento de dados de irradiância solar ( $W/m^2$ ) e velocidade do vento (m/s) por meio de metodologias “ensemble”. Após a aplicação de técnicas individualizadas de previsibilidade baseadas em AM (MLP, CFBP, RBF e SOM), as técnicas *ensemble*, definidas como PrevTP, RRE e o modelo híbrido WD-RNA-RRE, são implementadas visando à integração/combinção das técnicas aplicadas individualmente.

Os resultados são analisados considerando o RMSE, R, MAE, MSE (no PrevTP) e MAPE. Além disso, são criados gráficos com uma janela de tempo de 4 dias escolhidos aleatoriamente do conjunto de dados de teste, que relacionam os valores previstos e observados para os quatro modelos aplicados individualmente, para o modelo RRE, para o PrevTP e para o WD-RNA-RRE, considerando aplicações no Brasil e na Espanha e os recursos intermitentes sob análise. *Boxplots* com erros e gráficos de correlação são analisados para apresentar a totalidade dos dados de teste das aplicações individuais e das aplicações RRE, PrevTP e WD-RNA-RRE. Uma análise de intervalo quartil (50% dos dados apresentados) é realizada para entender a localização dos erros; assim, tendências de superestimação ou subestimação dos recursos eólicos e solares podem ser identificadas verificando a orientação interquartil em relação aos eixos positivo e negativo.

No presente capítulo, são apresentados os resultados das aplicações dos modelos individuais baseados em RNA, integração das RNA por meio da PrevTP, do RRE e do WD-RNA-RRE.

### 6.1 Previsões de Recurso Solar para Brasil e Espanha usando Técnicas Individuais, RRE, WD-RNA-RRE e PrevTP

As seções 6.1.1 e 6.1.2 apresentam os resultados das previsões individuais e das modelagens de conjunto aplicadas aos dados solares da Espanha e do Brasil, respectivamente.


#### 6.1.1 Resultados – Espanha

Na Figura 6.1 são apresentadas as correlações entre as previsões de recurso solar na Espanha obtidas pelas técnicas individualizadas. Os valores de R obtidos foram: 97% para MLP,

98% para CFBP, RBF e SOM. Na Figura 6.2 é apresentado o resultado da previsão usando os modelos RRE, WD-RNA-RRE e PrevTP para a previsão do recurso solar na Espanha.

Com RMSE de 19,127 W/m<sup>2</sup>, R de 0,997 e MAE de 13,613 W/m<sup>2</sup>, o modelo WD-RNA-RRE foi superior ao melhor modelo de desempenho individual (CFBP), que obteve RMSE de 28,955 W/m<sup>2</sup>, R de 0,992 e MAE de 25,977 W/m<sup>2</sup>, e superior às integrações desenvolvidas pelo PrevTP (com RMSE de 26,683 W/m<sup>2</sup>, R de 0,998 e MAE de 19,402 W/m<sup>2</sup>) e pelo RRE (com RMSE de 24,086 W/m<sup>2</sup>, R de 0,996 e MAE de 16,359 W/m<sup>2</sup>). Em termos de RMSE, os modelos RRE e WD-RNA-RRE obtiveram melhorias de 16% e 34%, respectivamente, quando comparados ao melhor modelo aplicado individualmente, e de 10% e 27%, respectivamente, quando comparados à integração realizada pelo PrevTP.

Figura 6.1 - Gráficos de correlação para MLP, RBF, CFBP e SOM, técnicas aplicadas individualmente para prever o recurso solar na Espanha



Fonte: Próprio autor.

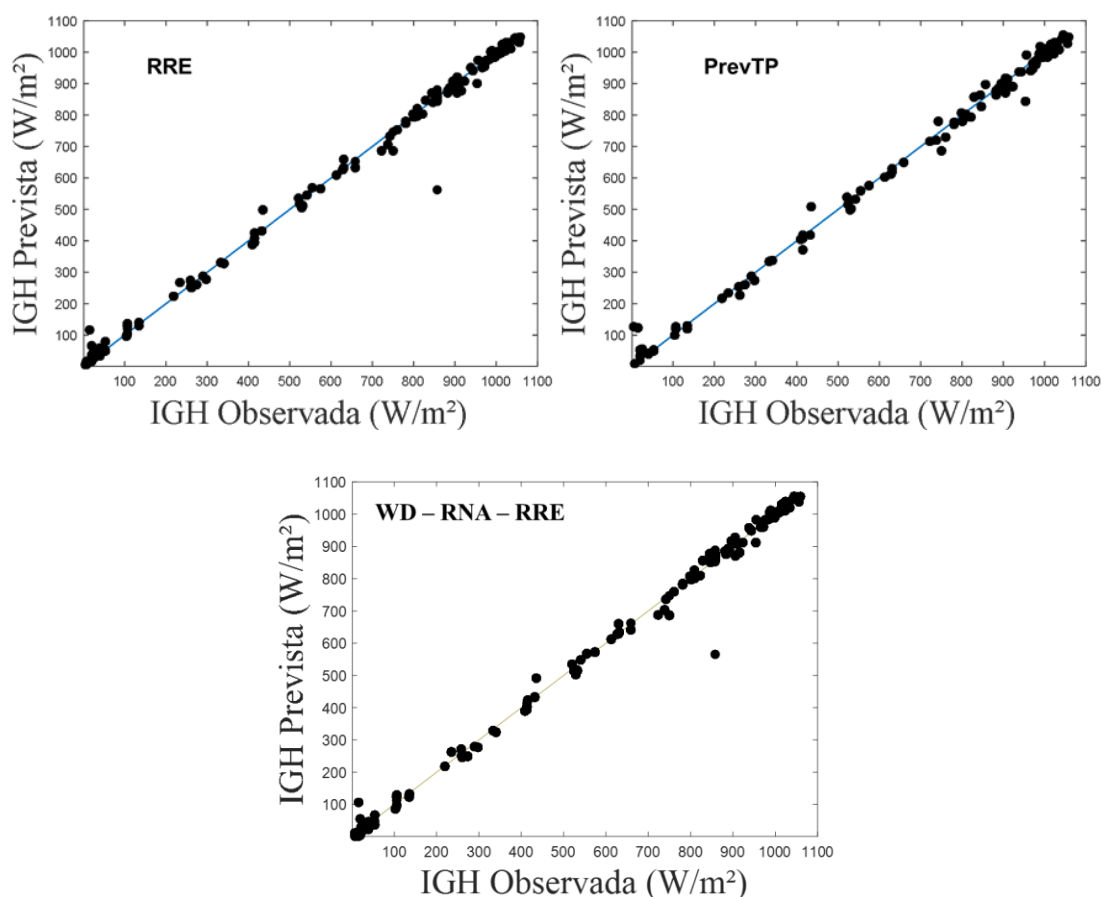
Embora o tamanho do banco de recurso solar seja semelhante para o Brasil e para a Espanha (5.408 para o Brasil e 4.893 para a Espanha), o comportamento do gráfico de



correlação para a Espanha, mostrado na Figura 6.2, é diferente do que será mostrado na Figura 6.8, na próxima seção, sobre os dados do Brasil. Observando a média (492,15 W/m<sup>2</sup> para o Brasil e 666,37 W/m<sup>2</sup> para a Espanha) e a mediana (495,52 W/m<sup>2</sup> para o Brasil e 798,41 W/m<sup>2</sup> para a Espanha), pode-se identificar uma tendência à concentração de valores elevados para os dados espanhóis, acima da média aritmética dos valores extremos (~525 W/m<sup>2</sup>).

Este fato deve-se à maior ocorrência de céu claro no local na Espanha; o local no Brasil é caracterizado pela passagem recorrente de nuvens, o que dispersa os dados medidos. Esse comportamento pode ser observado nos histogramas, que mostram “lacunas” no caso da Espanha, ou seja, concentração em valores específicos.


Figura 6.2 – Correlações e frequências de ocorrência dos modelos *ensemble* (RRE, WD-RNA-RRE e PrevTP) para a previsão solar na Espanha



Fonte: Próprio autor.

Na Figura 6.3 são apresentados os dados da validação cruzada e na Figura 6.4 a taxa de participação de cada metodologia individual na previsão RRE (calculada pela penalidade L2), respectivamente.


Figura 6.3 - Ajuste de hiperparâmetros com validação cruzada para a previsão solar na Espanha



Fonte: Próprio autor.

De acordo com a Figura 6.4, o modelo RRE utilizou o CFBP previsto de forma mais representativa, seguido pelo SOM e RBF. Assim, o modelo obteve o melhor das previsões e permitiu que todas as metodologias individuais contribuíssem para novos resultados.


Figura 6.4 - Contribuição de metodologias individuais em RRE para a previsão de recurso solar na Espanha



Fonte: Próprio autor.

Uma janela de dados de 4 dias (no caso dos dados solares, horas com projeção de luz solar) para o período de teste da previsão solar na Espanha, usando os modelos aplicados individualmente, o modelo RRE, o PrevTP e o WD-RNA-RRE, é mostrada na Figura 6.5.

Figura 6.5 - Dados solares observados e previstos dos métodos aplicados individualmente, RRE, WD-RNA-RRE e PrevTP na Espanha (janela de dados de 4 dias em 2009: 12 – 15/10 – excluindo horas noturnas)



Fonte: Próprio autor.

Na Tabela 6.1 são apresentados os valores de RMSE, R, MAE e MAPE para as técnicas individualizadas e para os modelos RRE, WD-RNA-RRE e PrevTP para os dados de recurso solar na Espanha. Considerando o MAPE, os modelos WD-RNA-RRE e RRE podem melhorar a acurácia dos resultados em relação às aplicações individualizadas. WD-RNA-RRE MAPE (10,780%) e RRE MAPE (11,261%) são inferiores ao modelo individual com melhor desempenho (CFBP com MAPE de 12,465%). O modelo PrevTP não conseguiu melhorar os resultados na aplicação aos dados solares da Espanha, em termos de MAPE, obtendo um valor de 35,581%, superior ao MAPE obtido pelo CFBP.

Tabela 6.1 - Métricas para avaliar metodologias individuais, aplicação do RRE, WD-RNA-RRE e PrevTP na Espanha

	MLP	CFBP	RBF	SOM	RRE	PrevTP	WD – RNA – RRE
<b>RMSE (W/m<sup>2</sup>)</b>	67,589	28,955	49,668	102,563	24,086	26,683	19,127
<b>R</b>	0,983	0,992	0,990	0,992	0,996	0,998	0,997
<b>MAE (W/m<sup>2</sup>)</b>	47,653	25,977	31,429	91,545	16,359	19,402	13,613
<b>MAPE (%)</b>	86,607	12,465	61,808	23,098	11,261	35,581	10,780

Fonte: Próprio autor.


As metodologias CFBP e RBF apresentaram melhor correlação do que as metodologias SOM e MLP. Em termos de MAPE, os modelos WD-RNA-RRE e RRE apresentaram desempenho similar e foram superiores ao PrevTP e modelos individuais. Considerando o

conjunto das métricas, o modelo WD-RNA-RRE apresentou o melhor desempenho. Os erros são apresentados em um *boxplot* na Figura 6.6.

A interpretação do gráfico *boxplot* segue as seguintes regras: a) Onde a haste vertical começa (de cima para baixo) é a indicação do valor máximo (exceto valores máximos extremos – *outliers*); b) Onde a haste termina, parte inferior, indica o valor mínimo (exceto os valores mínimos extremos – *outliers*); c) O retângulo na parte central possui três linhas horizontais em que: a linha de baixo é o primeiro quartil, a central indica a mediana e a de cima indica o terceiro quartil. A diferença entre o terceiro quartil e o primeiro quartil quantifica o intervalo interquartil.

Na Tabela 6.2 são apresentados os parâmetros para cada modelo aplicado individualmente, para o modelo RRE, para o WD-RNA-RRE e para o PrevTP.

Figura 6.6 - *Boxplot* da variação do erro de previsão solar na Espanha



Fonte: Próprio autor.

Para os dados solares da Espanha, os modelos preditivos individuais obtêm uma faixa de quartil entre 25,104 W/m<sup>2</sup> e 95,939 W/m<sup>2</sup>, enquanto o RRE obtêm uma faixa de quartil de 20,299 W/m<sup>2</sup>, similar ao modelo WD-RNA-RRE, com faixa de quartil de 20,449 W/m<sup>2</sup>. A partir da análise dos 3º e 1º quartis, os modelos SOM, CFBP e PrevTP tendem a subestimar os dados reais.

O WD-RNA-RRE é o modelo com a mediana mais próxima de 0, confirmando que seus valores estão mais próximos dos observados para o período de teste. Considerando os *outliers*, o WD-RNA-RRE é o modelo que reduz os valores com discrepância em relação à série padrão.

Tabela 6.2 - Parâmetros de *boxplot* usados para avaliar as metodologias individuais, RRE, WD-RNA-RRE e PrevTP na Espanha ( $W/m^2$ )


Modelo	Máximo (exceto <i>Outliers</i> )	quartil 3	mediana	quartil 1	Mínimo (exceto <i>Outliers</i> )	Intervalo interquartil
MLP	111,562	18,631	-3,595	-42,655	-139,939	61,286
CFBP	-0,056	-11,250	-28,864	-36,355	-26,414	25,104
RBF	73,869	24,561	6,042	-3,535	-52,397	28,096
SOM	-1,393	-34,140	-98,041	-130,079	-148,461	95,939
RRE	38,071	12,657	3	-7,643	-32,441	20,299
PrevTP	13,389	-6,108	-13,850	-24,998	-48,768	18,890
WD-RNA-RRE	35,974	10,466	-0,071	-9,982	-35,768	20,449

Fonte: Próprio autor.

### 6.1.2 Resultados – Brasil

Considerando a previsão de recurso solar no Brasil, na Figura 6.7 são mostradas as correlações entre as previsões obtidas através das técnicas aplicadas individualmente. Os valores de R para MLP e RBF são de 94%; para os modelos CFBP e SOM são de 97%.

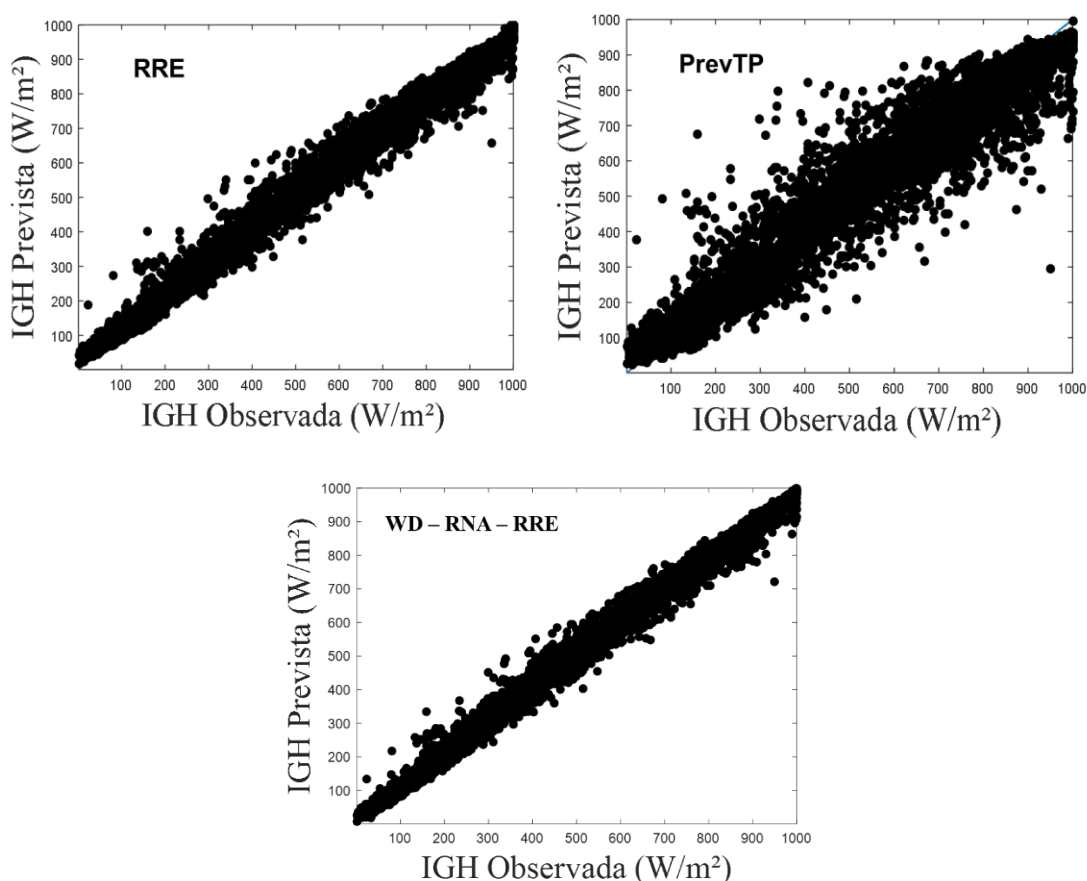
Figura 6.7 - Gráficos de correlação para MLP, RBF, CFBP e SOM, técnicas aplicadas individualmente para previsão do recurso solar no Brasil



Fonte: Próprio autor.

Os resultados dos modelos RRE, WD-RNA-RRE e PrevTP para previsão de recurso solar com dados do Brasil são mostrados na Figura 6.8. Os resultados dos modelos de combinação superaram as metodologias individuais mostradas na Figura 6.7. O modelo RRE teve um RMSE de 35,467 W/m<sup>2</sup>, R de 0,988 e MAE de 24,958 W/m<sup>2</sup>, que foram melhores que os resultados de CFBP e SOM: RMSE de 67,323 W/m<sup>2</sup> e 70,634 W/m<sup>2</sup>, R de 0,976 e 0,976 e MAE de 47,052 W/m<sup>2</sup> e 46,979 W/m<sup>2</sup>, respectivamente. Em termos de RMSE, há uma melhora de 47%. O modelo WD-RNA-RRE obteve RMSE de 27,471 W/m<sup>2</sup>, R de 0,995 e MAE de 17,670 W/m<sup>2</sup>, apresentando melhor desempenho que o RRE, PrevTP e os modelos individuais de melhor desempenho CFBP e SOM. Em relação ao RMSE, o WD-RNA-RRE obteve uma melhoria de 58% em relação aos melhores modelos individuais, e de 22% e 44% em relação ao RRE e PrevTP, respectivamente.

Figura 6.8 – Correlações e frequências de ocorrência para os resultados obtidos pelos modelos RRE, WD-RNA-RRE e PrevTP na previsão solar no Brasil




Fonte: Próprio autor.

O modelo PrevTP foi inferior aos modelos RRE e WD-RNA-RRE; no entanto, conseguiu obter melhorias em relação aos modelos individuais com RMSE de 48,890 W/m<sup>2</sup>, R

de 0,988 e MAE de 32,574 W/m<sup>2</sup>. Em termos de RMSE e comparado ao modelo individual com melhor desempenho (CFBP), o PrevTP melhorou o RMSE em torno de 27%.


Na Figura 6.9 são mostrados os dados os dados de validação cruzada. A taxa de participação de cada metodologia individual na previsão por meio do RRE (penalidade L2) pode ser vista na Figura 6.10.

Figura 6.9 – Ajuste de hiperparâmetros com validação cruzada para a previsão solar no Brasil



Fonte: Próprio autor.

Figura 6.10 – Contribuição das metodologias individuais no RRE para a previsão de recurso solar no Brasil



Fonte: Próprio autor.

De acordo com a Figura 6.10, o modelo RRE utilizou as previsões CFBP e SOM de forma mais representativa. Na Tabela 6.3 são apresentados os valores de RMSE, R, MAE e MAPE para as técnicas individualizadas, para o RRE, para o WD-RNA-RRE e para o PrevTP definido para os dados de recurso solar no Brasil. Os modelos CFBP e SOM foram superados

pelos modelos RRE, WD-RNA-RRE e PrevTP, sendo o WD-RNA-RRE o modelo *ensemble* de melhor desempenho na previsão.

Tabela 6.3 - Métricas para avaliar metodologias individuais, RRE, WD-RNA-RRE e PrevTP no Brasil


	MLP	CFBP	RBF	SOM	RRE	PrevTP	WD – RNA – RRE
<b>RMSE (W/m<sup>2</sup>)</b>	101,045	67,323	106,133	70,634	35,467	48,890	27,471
<b>R</b>	0,944	0,976	0,942	0,976	0,988	0,988	0,995
<b>MAE (W/m<sup>2</sup>)</b>	69,989	47,053	76,292	46,979	24,958	32,574	17,670
<b>MAPE (%)</b>	40,417	24,207	32,824	25,556	14,191	18,053	8,946

Fonte: Próprio autor.

Analisando a Tabela 6.3, o WD-RNA-RRE mostrou-se como a melhor aplicação (com um MAPE de 8,946%), seguido dos modelos RRE (com MAPE de 14,191%) e PrevTP (com o MAPE de 18,053%), ambos os MAPE dos modelos *ensemble* foram inferiores ao MAPE obtido pelo melhor modelo aplicado individualmente para a previsão do recurso solar no Brasil (CFBP com 24,207%).

Uma janela de dados de 4 dias referente ao período de teste da previsão solar no Brasil usando os modelos aplicados individualmente, o modelo RRE, o WD-RNA-RRE e o PrevTP é apresentada na Figura 6.11.

Figura 6.11 – Dados solares observados e previstos dos métodos aplicados individualmente, do RRE, do WD-RNA-RRE e do PrevTP no Brasil (janela de 4 dias em 2015: 31/10 – 3/11 – excluindo horas noturnas)



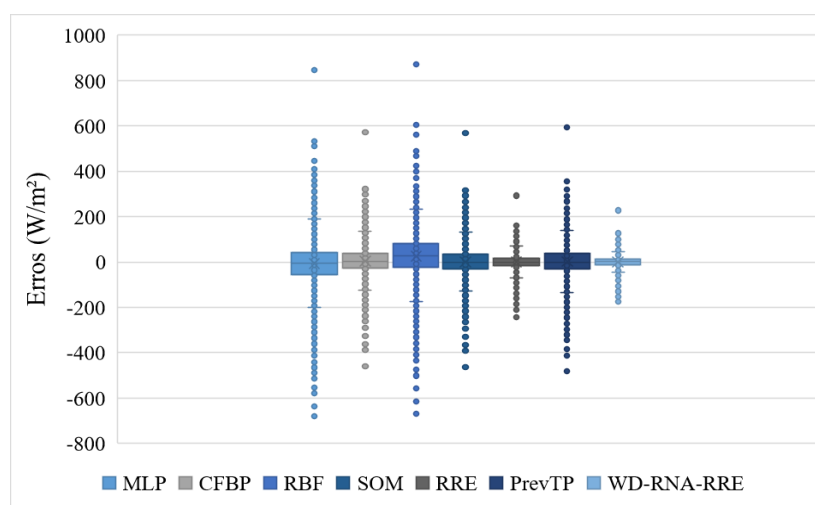
Fonte: Próprio autor.

Um *boxplot* com os erros é apresentado na Figura 6.12. Na Tabela 6.4 são apresentados os parâmetros do *boxplot* para cada modelo aplicado individualmente, para o RRE, o WD-



RNA-RRE e o PrevTP na previsão solar no Brasil. Com erros mais próximos de zero e menos *outliers*, os modelos WD-RNA-RRE e RRE apresentam os melhores resultados: faixa de quartil de 23,132 W/m<sup>2</sup> e 35,006 W/m<sup>2</sup>, respectivamente, menos da metade da faixa de quartil obtida pelos modelos CFBP e SOM (faixa de quartil de 65,291 W/m<sup>2</sup>). O modelo PrevTP conseguiu melhorar os resultados dos modelos individuais em termos de mediana (0,181 W/m<sup>2</sup>); no entanto, em termos de intervalo interquartil, ainda tem valores superiores ao RRE, CFBP e SOM, mostrando que o modelo teve desempenho similar aos melhores modelos individuais.

Figura 6.12 - *Boxplot* da variação do erro de previsão solar no Brasil



Fonte: Próprio autor.

Tabela 6.4 - Parâmetros de *boxplot* para avaliar as metodologias individuais, RRE, WD-RNA-RRE e PrevTP no Brasil (W/m<sup>2</sup>)

Modelo	Máximo (exceto Outliers)	quartil 3	mediana	quartil 1	Mínimo (exceto Outliers)	Intervalo interquartil
MLP	187,983	42,611	-5,254	-54,545	-200,280	97,156
CFBP	135,616	37,617	3,068	-27,674	-125,544	65,291
RBF	233,159	80,009	28,388	-22,332	-175,533	102,341
SOM	131,616	33,617	-0,932	-31,674	-129,544	65,291
RRE	69,814	17,838	-0,595	-17,168	-68,499	35,006
PrevTP	138,237	36,361	0,181	-31,657	-133,654	68,018
WD-RNA-RRE	46,412	11,705	0,983	-11,428	-46,034	23,132

Fonte: Próprio autor.

Os erros obtidos pelas previsões individuais para as duas localidades são apresentados na Tabela 6.5.

Tabela 6.5 - Resumo de erros obtidos a partir dos sinais reconstruídos para o recurso solar nas duas localidades

Sinais reconstruídos	Recurso	Recurso
	solar/Espanha	solar/Brasil
RMSE (W/m <sup>2</sup> )		
MLP	55,313	97,383
RBF	32,415	98,110
SOM	95,836	72,128
CFBP	32,163	52,254

Fonte: Próprio autor.

Considerando o desempenho dos modelos individuais descritos nas Tabelas 6.1 e 6.3, observa-se que, os valores de RMSE descritos na Tabela 6.5, para os sinais reconstruídos, são, em alguns casos (MLP, RBF e SOM na Espanha e MLP, CFBP e RBF no Brasil), menores que os modelos aplicados inicialmente, sem o uso do pré-processamento via WT. Assim, fica demonstrado que o uso do pré-processamento, por meio de WT, pode melhorar o desempenho dos modelos individuais e, conseqüentemente, do resultado do WD-RNA-RRE, como foi confirmado pelo bom desempenho do modelo híbrido quando aplicado aos dados solares nas duas localidades.

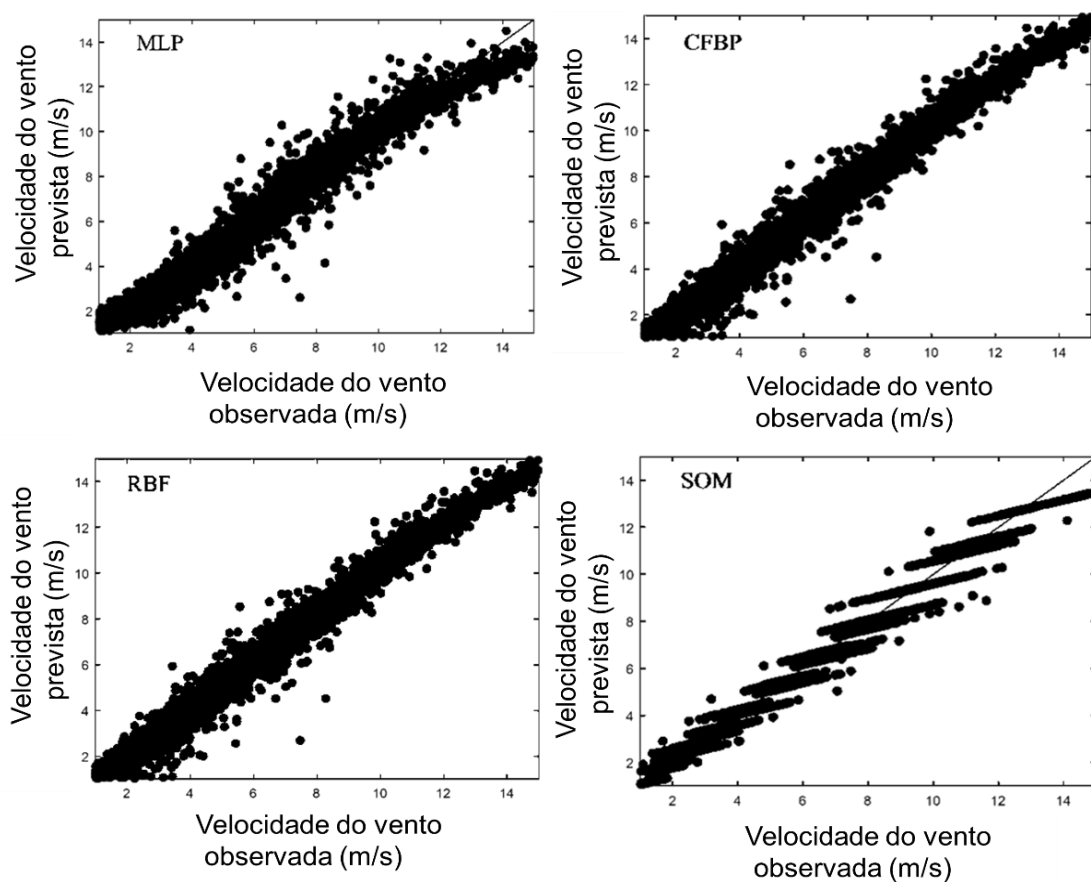
## 6.2 Previsões de Recurso Eólico para Brasil e Espanha usando Técnicas Individuais, RRE, WD-RNA-RRE e PrevTP

As seções 6.2.1 e 6.2.2 apresentam os resultados das previsões individuais e das modelagens de conjunto aplicadas aos dados eólicos da Espanha e do Brasil, respectivamente.

### 6.2.1 Resultados – Espanha

Na Figura 6.13 são apresentadas as correlações entre as previsões do recurso eólico na Espanha usando técnicas individualizadas. Os valores de R para os métodos aplicados individualmente ficaram entre 97 e 98%.

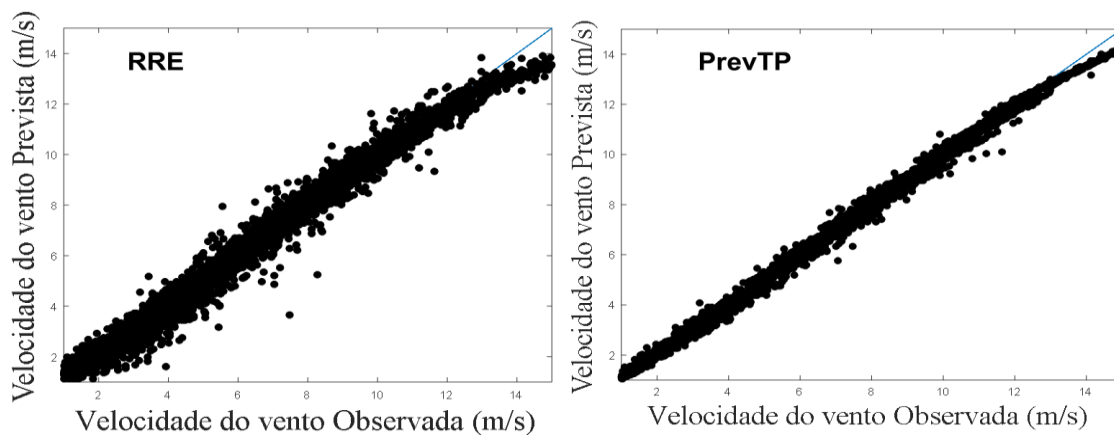
Figura 6.13 - Gráficos de correlação para as técnicas MLP, RBF, CFBP e SOM aplicadas individualmente à previsão do vento na Espanha




Fonte: Próprio autor.

Na Figura 6.14 é apresentada a correlação para os resultados do RRE, WD-RNA-RRE e do PrevTP.

Figura 6.14 - Correlações e frequências de ocorrência para os resultados obtidos pelos modelos RRE, WD-RNA-RRE e PrevTP na previsão eólica na Espanha






Fonte: Próprio autor.


A validação cruzada é apresentada na Figura 6.15. A taxa de participação de cada metodologia individual (definida pela penalidade L2) na previsão por conjunto é apresentada na Figura 6.16, indicando que o modelo RRE utilizou predominantemente a participação dos modelos MLP, SOM e CFBP para gerar os melhores resultados.

Figura 6.15 - Ajuste de hiperparâmetros com validação cruzada para a previsão do vento na Espanha



Fonte: Próprio autor.

Figura 6.16 - Contribuição de metodologias individuais em RRE para a previsão de recurso eólico na Espanha



Fonte: Próprio autor.

Na Tabela 6.6 são apresentados os valores de RMSE, R, MAE e MAPE para as técnicas individualizadas, para o RRE, para o WD-RNA-RRE e para o PrevTP para dados de recurso eólico na Espanha. Os modelos individuais obtiveram RMSE entre 0,437 m/s e 0,533 m/s, R entre 97 e 98% e MAE entre 0,276 m/s e 0,374 m/s.

Tabela 6.6 - Métricas para avaliar metodologias individuais, RRE, WD-RNA-RRE e PrevTP na Espanha

	MLP	CFBP	RBF	SOM	RRE	PrevTP	WD – RNA – RRE
<b>RMSE (m/s)</b>	0,437	0,504	0,533	0,510	0,337	0,133	0,370
<b>R</b>	0,990	0,988	0,985	0,987	0,989	0,998	0,981
<b>MAE (m/s)</b>	0,276	0,318	0,374	0,354	0,216	0,089	0,250
<b>MAPE (%)</b>	7,186	7,618	9,327	7,280	5,491	2,060	5,810

Fonte: Próprio autor.


Essas métricas foram superadas pelos modelos RRE (com RMSE de 0,337 m/s, R de 0,989 e MAE de 0,216 m/s), WD-RNA-RRE (com RMSE de 0,370 m/s, R de 0,981 e MAE de 0,250 m/s) e PrevTP (com RMSE de 0,133 m/s, R de 0,998 e MAE de 0,089 m/s) na previsão do recurso eólico. Diferentemente das aplicações para o recurso solar, onde os modelos WD-RNA-RRE e RRE foram superiores ao PrevTP, na aplicação para o recurso eólico na Espanha, o modelo PrevTP foi superior aos modelos individuais e aos WD-RNA-RRE e RRE.

Vale ressaltar que os três modelos de conjunto (WD-RNA-RRE, RRE e PrevTP) conseguiram melhorar o desempenho em relação aos modelos aplicados individualmente. Em termos de RMSE, os modelos RRE e WD-RNA-RRE, comparados com o melhor modelo aplicado individualmente, apresentaram uma redução de erro de 22,8% e 15,3% e o modelo PrevTP obteve uma redução de quase 69,5%.

Considerando as técnicas aplicadas individualmente à previsão de vento na Espanha, o MLP apresentou um desempenho geral superior às outras três técnicas, obtendo um RMSE, R e MAE de 0,437 m/s, 98% e 0,276 m/s, respectivamente.

Uma janela de dados de 4 dias, referente ao período de teste da previsão de vento na Espanha, usando os modelos aplicados individualmente, o RRE, o WD-RNA-RRE e o PrevTP, é apresentada na Figura 6.17.

Figura 6.17 - Dados de vento observados e previstos dos métodos aplicados individualmente, RRE, WD-RNA-RRE e PrevTP na Espanha (janela de dados de 4 dias – 2009: 23 – 25/10)




Fonte: Próprio autor.

De acordo com a Tabela 6.6, o RRE apresenta um MAPE de 5,491%, o WD-RNA-RRE apresenta um MAPE de 5,810% e o PrevTP um MAPE de 2,060%. O método individual com melhor desempenho (MLP) obteve um MAPE de 7,186%, confirmando o melhor desempenho do PrevTP, seguido pelos modelos RRE e WD-RNA-RRE.

Um *boxplot* com os erros é mostrado na Figura 6.18. Na Tabela 6.7 são apresentados os parâmetros do *boxplot* para cada modelo aplicado individualmente e para os modelos de conjunto RRE, WD-RNA-RRE e PrevTP na previsão de vento na Espanha.

Figura 6.18 - *Boxplot* da variação do erro de previsão do vento na Espanha



Fonte: Próprio autor.

Tabela 6.7 - Parâmetros *boxplot* para avaliar metodologias individuais, RRE, WD-RNA-RRE e PrevTP na Espanha (m/s)

Modelo	Máximo		mediana	quartil 1	Mínimo		Intervalo interquartil
	(exceto <i>Outliers</i> )	quartil 3			(exceto <i>Outliers</i> )	quartil 3	
<b>MLP</b>	0,590	0,152	-0,031	-0,182	-0,672	0,334	
<b>CFBP</b>	0,415	0,009	-0,129	-0,293	-0,694	0,302	
<b>RBF</b>	0,969	0,188	-0,082	-0,334	-1,051	0,523	
<b>SOM</b>	1,090	0,307	0,025	-0,222	-0,999	0,529	
<b>RRE</b>	0,494	0,124	-0,026	-0,154	-0,542	0,277	
<b>PrevTP</b>	0,560	0,128	-0,034	-0,179	-0,615	0,146	
<b>WD-RNA-RRE</b>	0,679	0,167	-0,013	-0,185	-0,711	0,352	

Fonte: Próprio autor.

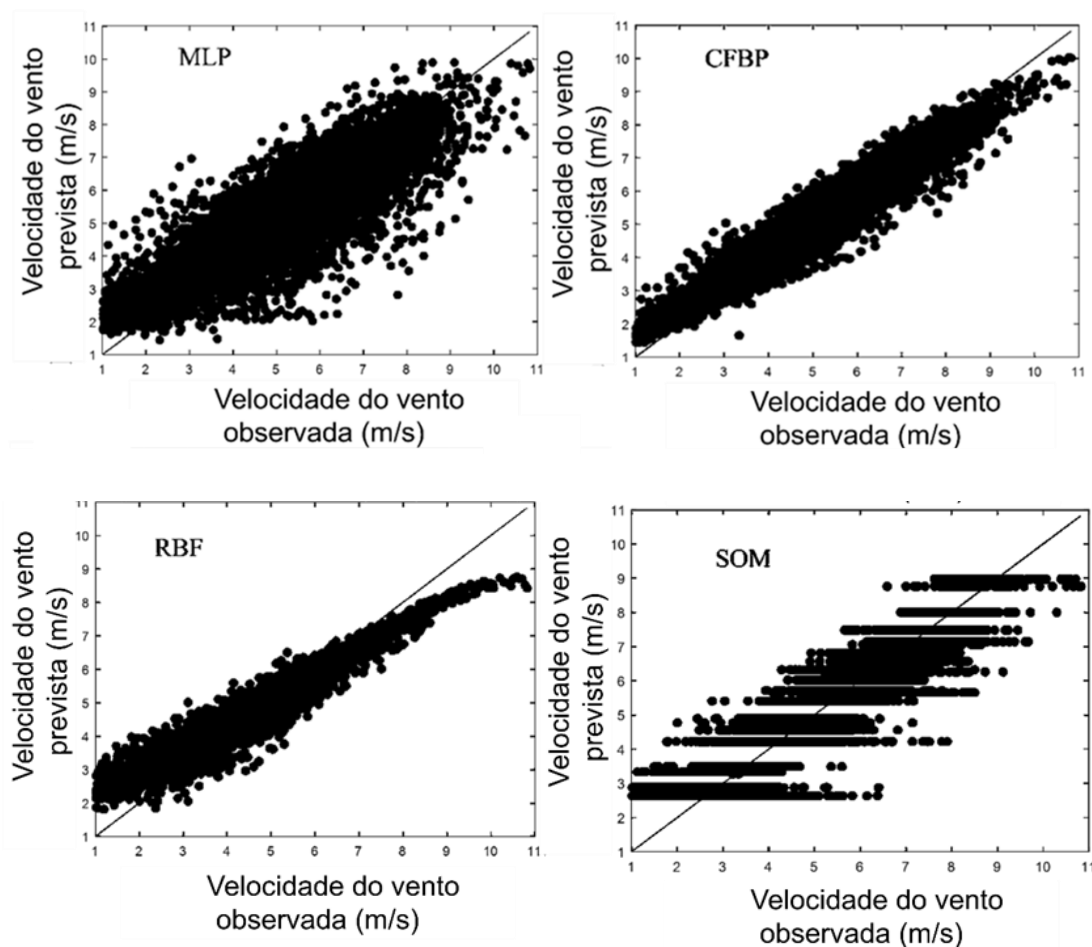
Analisando a Figura 6.18, os modelos RRE, PrevTP e WD-RNA-RRE apresentam menos *outliers* e erros próximos de zero. Nessa aplicação, considerando as métricas de avaliação (RMSE, R, MAE e MAPE) e o *boxplot* dos erros com seus parâmetros, o PrevTP apresentou desempenho superior ao RRE, WD-RNA-RRE e modelos individuais.

Considerando a Tabela 6.7, o intervalo interquartil do PrevTP apresenta o menor valor (0,146 m/s), comparado aos melhores modelos individuais (MLP e CFBP) e com os RRE e WD-RNA-RRE, que foram superiores aos melhores modelos individuais, com intervalos interquartis de 0,277 m/s e 0,352 m/s, respectivamente.

### 6.2.2 Resultados - Brasil

Considerando o recurso eólico no Brasil, nas Figuras 6.19 a 6.22 são apresentadas correlações entre as previsões no país utilizando técnicas individualizadas, correlação e frequência de ocorrência para os resultados do RRE, do WD-RNA-RRE e PrevTP, validação cruzada para definição de parâmetros e taxa de participação de cada metodologia individualizada na previsão por meio do RRE, respectivamente. Na Figura 6.19 são apresentada as correlações entre as previsões do recurso eólico no Brasil usando técnicas individualizadas. Os valores de R para os métodos aplicados individualmente ficaram entre 85 e 97%.


Figura 6.19 - Gráficos de correlação para MLP, RBF, CFBP e SOM, técnicas aplicadas individualmente para previsão do recurso eólico no Brasil




Fonte: Próprio autor.

Na Figura 6.20 é apresentada a correlação para os resultados do RRE, WD-RNA-RRE e do PrevTP, que obtiveram valores de R em torno de 98%.

Figura 6.20 - Correlações e frequências de ocorrência para os resultados obtidos pelos modelos RRE, WD-RNA-RRE e PrevTP na previsão eólica no Brasil



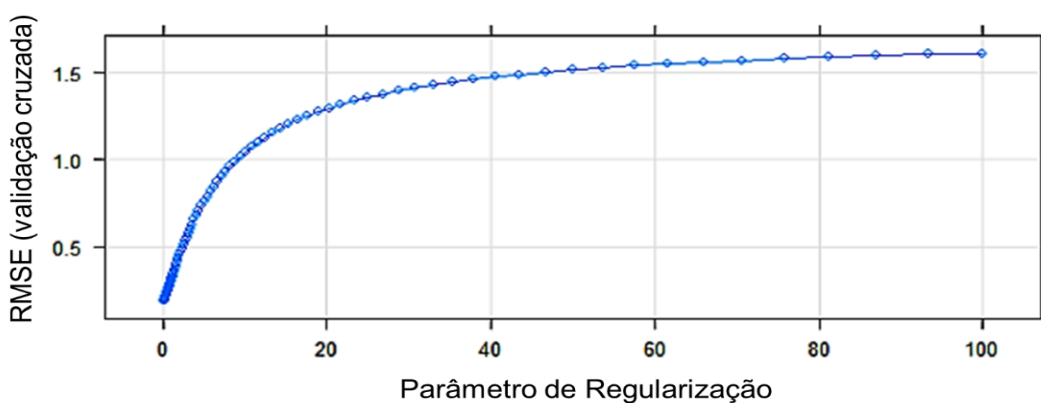




Fonte: Próprio autor.


A validação cruzada é apresentada na Figura 6.21. De acordo com a Figura 6.22, o modelo RRE utilizou predominantemente a participação dos modelos CFBP, RBF e SOM para gerar os melhores resultados.

Figura 6.21 - Ajuste de hiperparâmetros com validação cruzada para previsão de vento no Brasil



Fonte: Próprio autor.

Figura 6.22 - Contribuição de metodologias individuais em RRE para a previsão de recurso eólico no Brasil



Fonte: Próprio autor.

De acordo com a Tabela 6.8, o modelo RRE obteve RMSE de 0,188 m/s, R de 0,989 e MAE de 0,138 m/s, resultados superiores aos desempenhos de CFBP e RBF (anteriormente os melhores resultados): os modelos CFBP e RBF obtiveram RMSE, R e MAE de 0,449 e 0,548 m/s, 96 e 97%, 0,342 e 0,409 m/s, respectivamente, também superiores aos modelos WD-RNA-RRE que obteve RMSE de 0,354 m/s, R de 0,978 e MAE de 0,265 m/s e PrevTP que obteve RMSE de 0,509 m/s, R de 0,977 e MAE de 0,413 m/s.

De acordo com a Tabela 6.8, o RRE apresenta um MAPE de 3,927%, uma redução de 5,42% em relação ao melhor modelo individual (CFBP com MAPE de 9,345%). O RRE apresentou MAPE menor que os modelos *ensemble* WD-RNA-RRE e PrevTP que obtiveram MAPE de 9,480% e 12,820%, respectivamente.

Tabela 6.8 - Métricas para avaliar as metodologias individuais, RRE, WD-RNA-RRE e PrevTP no Brasil


	MLP	CFBP	RBF	SOM	RRE	PrevTP	WD – RNA – RRE
<b>RMSE (m/s)</b>	0,893	0,448	0,548	0,713	0,188	0,509	0,354
<b>R</b>	0,856	0,968	0,977	0,911	0,989	0,977	0,978
<b>MAE (m/s)</b>	0,678	0,342	0,409	0,544	0,138	0,413	0,265
<b>MAPE (%)</b>	18,228	9,345	14,155	16,433	3,927	12,820	9,480

Fonte: Próprio autor.

Assim, o modelo RRE apresentou uma melhoria de RMSE de mais de 58% em relação ao modelo aplicado individualmente com o melhor desempenho global (CFBP). O PrevTP na aplicação aos dados eólicos do Brasil não conseguiu melhorar o desempenho do modelo individual com melhor desempenho, já o WD-RNA-RRE foi superior ao PrevTP e ao melhor modelo aplicado individualmente.

Na Figura 6.23 é ilustrada uma janela de 4 dias para o período de teste da previsão de vento, usando os modelos aplicados individualmente (RRE, WD-RNA-RRE e PrevTP) no Brasil.


Figura 6.23 - Dados de vento observados e previstos para os métodos aplicados individualmente, o RRE, o WD-RNA-RRE e o PrevTP no Brasil (janela de dados de 4 dias – 2009: 24 – 27/10)



Fonte: Próprio autor.

Um *boxplot* com os erros dos modelos individuais, do RRE, do WD-RNA-RRE e do PrevTP na previsão de vento no Brasil é apresentado na Figura 6.24.

Figura 6.24 - *Boxplot* da variação dos erros de previsão de vento no Brasil



Fonte: Próprio autor.

O modelo RRE apresenta menos *outliers*, comprovando que a sua integração permite o ajuste de *outliers*. A mediana do modelo RRE é a mais próxima de zero entre as aplicações (-0,002 m/s) para previsão de vento no Brasil. Considerando a Tabela 6.9, o intervalo interquartil

(50% dos dados apresentados) do modelo RRE varia de -0,111 a 0,112 (m/s), sendo o menor (0,223 m/s) entre as aplicações.

Tabela 6.9 - Parâmetros de *boxplot* para avaliação de metodologias individuais, RRE, WD-RNA-RRE e PrevTP no Brasil (m/s)

Modelo	Máximo				Mínimo		Intervalo interquartil
	(exceto Outliers)	quartil 3	mediana	quartil 1	(exceto Outliers)		
MLP	1,875	0,317	-0,208	-0,722	-2,315	1,038	
CFBP	0,923	0,140	-0,122	-0,381	-1,165	0,523	
RBF	1,228	0,154	-0,179	-0,563	-1,639	0,717	
SOM	1,692	0,342	-0,107	-0,571	-1,939	0,912	
RRE	0,445	0,112	-0,002	-0,111	-0,446	0,223	
PrevTP	0,597	-0,111	-0,347	-0,593	-1,316	0,482	
WD – RNA – RRE	0,816	0,208	-0,006	-0,215	-0,773	0,423	

Fonte: Próprio autor.

Os erros obtidos pelas previsões individuais para as duas localidades são apresentados na Tabela 6.10.

Tabela 6.10 - Resumo de erros obtidos a partir dos sinais reconstruídos para o recurso solar nas duas localidades

Sinais reconstruídos	Recurso	Recurso
	eólico/Espanha	eólico/Brasil
RMSE (m/s)		
MLP	0,791	0,762
RBF	0,456	0,443
SOM	0,875	0,710
CFBP	0,489	0,682

Fonte: Próprio autor.

Observa-se que os valores de RMSE descritos na Tabela 6.10, para os sinais reconstruídos, são, para os seguintes casos: RBF e CFBP na Espanha e MLP, RBF e SOM no Brasil, menores que os modelos aplicados inicialmente sem o uso do pré-processamento via WT, demonstrando que, em algumas aplicações, o uso do pré-processamento por meio de WT pode melhorar o desempenho dos modelos individuais e, conseqüentemente, do resultado do WD-RNA-RRE.

Analisando apenas as aplicações individuais (simples), o CFBP apresenta um bom desempenho em relação as outras metodologias de previsão de recurso eólico e solar; esse

comportamento pode estar relacionado à estruturação de sua arquitetura, que combina MLP simples (conexões adicionais) e aumenta as oportunidades de correção de erros durante o processo de aprendizagem. Considerando a previsão solar e eólica no Brasil e na Espanha, os modelos WD-RNA-RRE e RRE podem reduzir *outliers* e erros (RMSE, MAPE, R e MAE) e prever com mais precisão, provando ser uma ferramenta *ensemble* útil para o aprimoramento de previsões isoladas.

Considerando as aplicações individuais, usando os sinais decompostos por meio de WT, e analisando as Tabelas 6.5 e 6.10, que apresentam os erros obtidos após a reconstrução dos sinais previstos, as RNA do tipo CFBP e RBF obtiveram um bom desempenho na previsão dos componentes de aproximação e de detalhes entre as previsões individuais para o recurso eólico, nas duas localidades, e para o recurso solar no Brasil. Para as aplicações ao recurso solar na Espanha, os modelos SOM e CFBP obtiveram os melhores rendimentos.

Comparando os modelos PrevTP, WD-RNA-RRE e RRE, pode-se observar que o RRE sem o pré-processamento obteve melhorias em relação aos modelos individuais em todas as aplicações. O PrevTP conseguiu superar o RRE apenas na aplicação ao recurso eólico na Espanha; no entanto, apesar da superação por meio do PrevTP, o RRE foi superior aos modelos individuais. O modelo híbrido WD-RNA-RRE foi superior aos modelos individuais e aos modelos PrevTP e RRE nas aplicações aos dados solares nas duas localidades, mas não conseguiu superar o PrevTP na aplicação aos dados eólicos da Espanha e o RRE nos dados eólicos do Brasil. Mas superou os modelos aplicados individualmente em todas as simulações.

Importante ressaltar que os modelos *ensemble* apresentaram-se como ferramentas relevantes quando se trata da combinação de previsões para recursos intermitentes. O bom desempenho preditivo e a melhoria da precisão dos resultados obtida pelos modelos RRE, WD-RNA-RRE e o PrevTP, podem trazer benefícios aos tomadores de decisão, reduzir o custo de geração líquida e minimizar os impactos na segurança da rede. Adicionalmente, os benefícios de uma previsão solar e eólica com mínimo erro pode ser relevantes em mercados de desequilíbrio de energia, trazendo uma redução nos recursos de *backup*.

Considerando as revisões teóricas apresentadas na Seção 3, a Tabela 6.11 foi desenvolvida visando avaliar como estão posicionados, em termos de precisão, os resultados das previsões obtidas nesta Tese em relação às precisões de parte dos artigos incluídos na qSLR (tema solar e eólico).

Tabela 6.11 - Resumo de erros obtidos por parte dos artigos considerados na qSLR e das metodologias aplicadas nesta Tese

<b>Referências</b>	<b>Meta de previsão</b>	<b>Resultados obtidos (em termos de MAPE - %)</b>
(Jung <i>et al.</i> , 2020)	Geração Fotovoltaica	11,535 e 10,805
(Hu <i>et al.</i> , 2018)	Geração Fotovoltaica	RBF – 7,4 e AR – 13,6
(Heydari <i>et al.</i> , 2019)	Irradiância Solar	1,7275
(Lima <i>et al.</i> , 2020)	Irradiância Solar	Espanha – 5,36 e Brasil – 4,52%
(Bouzgou & Gueymard. 2019)	IHG	7,4 e 10,77
(Liu <i>et al.</i> , 2023)	Geração Eólica	19,58
(Jiang <i>et al.</i> , 2023)	Velocidade do Vento	3,2 e 11,08
(Cui <i>et al.</i> , 2023)	Geração Eólica	0,094 – 0,154 (MAPE/Capacidade instalada do parque)
(Carneiro <i>et al.</i> , 2022)	Velocidade do Vento	1,13
(Duan <i>et al.</i> , 2022)	Velocidade do Vento	1,18 - 5,43 (na melhor aplicação e em diferentes locais)
RRE – Brasil (1)	Velocidade do Vento	3,927
RRE – Brasil (2)	Irradiância Solar	14,191
RRE – Espanha (1)	Velocidade do Vento	5,491
RRE – Espanha (2)	Irradiância Solar	11,261
WD-RNA-RRE – Brasil (1)	Velocidade do Vento	9,480
WD-RNA-RRE – Brasil (2)	Irradiância Solar	8,946
WD-RNA-RRE – Espanha (1)	Velocidade do Vento	5,810
WD-RNA-RRE – Espanha (2)	Irradiância Solar	10,780

Fonte: Próprio autor.

Considerando uma variação de MAPE entre 3,9% e 14,19%, obtida pelas diferentes aplicações desta Tese, e observando os erros (em termos de MAPE) obtidos por algumas referências utilizadas nas revisões teóricas (Seção 3), estes variando entre 1,18% e 19,58%, pode-se observar que as aplicações desta Tese estão melhores ou similares a outras aplicações encontradas na literatura.

Neste capítulo, foram apresentados os resultados e as discussões referentes às técnicas individuais, baseadas em AM, e também às metodologias de conjunto aplicadas à previsão solar e eólica, no Brasil e na Espanha. Os resultados demonstraram a eficácia das técnicas de combinação visando à melhoria dos resultados das previsões obtidas pelos modelos individuais.

As técnicas se mostraram eficazes para aplicação em localidades com diferentes latitudes e condições climáticas. As conclusões desta Tese serão apresentadas no próximo Capítulo.

## 7 CONCLUSÃO

Os efeitos da intermitência dos recursos eólico e solar podem ser reduzidos usando ferramentas apropriadas para prever sua disponibilidade, obtendo modelos que podem ser utilizados para o gerenciamento de usinas eólicas e fotovoltaicas, visando uma geração de eletricidade otimizada. Esta Tese vem com 6.1a proposta de aplicar duas metodologias *ensemble*, a) RRE; e b) WD-RNA-RRE, e compará-las com o modelo PrevTP. As diferentes técnicas de integração agregam os resultados de técnicas de AM, CFBP, SOM, RBF e MLP, usando dados de recursos eólicos e solares do Brasil e da Espanha.

Como demonstração da capacidade aprimorada das metodologias *ensemble*, os erros das integrações desenvolvidas pelas técnicas WD-RNA-RRE e RRE, para as quatro técnicas de AM, apresentaram melhor desempenho, em comparação com os erros das metodologias individualizadas, em todos os casos estudados. O PrevTP conseguiu melhorar o desempenho das técnicas aplicadas individualmente em duas das quatro aplicações.

Considerando os modelos individuais para a previsão de vento no Brasil, CFBP e RBF obtiveram os melhores desempenhos, com RMSE, R e MAE de 0,449 e 0,548 m/s, 96 e 97%, 0,342 e 0,409 m/s, respectivamente. Considerando a previsão de vento na Espanha, o MLP obteve o melhor desempenho com RMSE de 0,437 m/s, R de 99% e MAE de 0,276 m/s. O CFBP apresentou os melhores resultados na previsão do recurso solar no Brasil, com RMSE de 67,323 W/m<sup>2</sup>, R de 97% e MAE de 47,053 W/m<sup>2</sup>. Na Espanha, o modelo único com melhor desempenho foi o CFBP, com RMSE de 24,086 W/m<sup>2</sup>, R de 0,996 e MAE de 16,359 W/m<sup>2</sup>.

O modelo híbrido foi superior aos modelos RRE e PrevTP, em termos de RMSE, MAPE e R, nas aplicações ao recurso solar no Brasil e na Espanha. O modelo WD-RNA-RRE obteve na aplicação solar na Espanha um RMSE de 19,127 W/m<sup>2</sup>, MAPE de 10,780% e R de 0,997; para o recurso solar no Brasil, foi calculado um RMSE de 27,471 m/s, MAPE de 8,946% e R de 0,995. Para a previsão eólica no Brasil, o modelo híbrido foi superior ao modelo PrevTP e inferior ao RRE, com um RMSE de 0,354 W/m<sup>2</sup>, MAPE de 0,265% e um R de 0,978. Para o recurso eólico na Espanha, o modelo WD-RNA-RRE melhorou o desempenho dos modelos individuais, mas não conseguiu superar o desempenho dos modelos RRE e PrevTP.

Para o recurso solar na Espanha, o modelo RRE obteve RMSE de 24,086 W/m<sup>2</sup>, MAPE de 11,261% e R de 0,996; para o recurso eólico, foi calculado um RMSE de 0,337 m/s, MAPE de 5,491% e R de 0,989. Para a previsão solar no Brasil, foi calculado um RMSE de 35,467



W/m<sup>2</sup>, MAPE de 14,191% e um R de 0,988: para o recurso eólico, um RMSE de 0,188 m/s, MAPE de 3,927% e um R de 0,989.

O modelo RRE melhorou as previsões solares e eólicas, em termos de RMSE, na Espanha em 16% e 22%, respectivamente, em comparação com os melhores modelos individuais. Para as previsões do RRE para os recursos solares e eólicos no Brasil, o RMSE foi reduzido em 47,5% e mais de 58%, respectivamente, em comparação com os melhores modelos individuais. O modelo híbrido obteve uma melhoria nas previsões solares e eólicas na Espanha, em termos de RMSE, de 33% e 15%, em relação aos modelos individuais com melhor desempenho. Nas previsões solares e eólicas no Brasil, o modelo híbrido conseguiu melhorar o seu desempenho, em relação aos melhores modelos individuais, em 59% e 20%, respectivamente.

Para o modelo RRE, analisando os gráficos *boxplots* com os erros dos dados solares, é possível observar que os erros (50% dos dados) da previsão solar no Brasil apresentam um intervalo interquartil de 35,006 W/m<sup>2</sup>, erros mais próximos de zero e menos *outliers*. A previsão solar na Espanha, com intervalo interquartil de 20,299 W/m<sup>2</sup>, apresenta a mediana mais baixa e valores mais próximos de 0. Considerando o *boxplot* com os erros dos dados de vento no Brasil, o RRE apresenta uma mediana próxima de zero (-0,002 m/s) e um intervalo quartil de 0,223 (m/s). Quando aplicado a dados de vento na Espanha, o RRE apresenta menos valores discrepantes e erros mais próximos de zero (intervalo interquartil de 0,277 m/s).

Analisando os gráficos *boxplots* referentes às aplicações híbridas, temos as seguintes conclusões: por meio dos erros dos dados solares, é possível observar que os erros (50% dos dados) das previsões solares no Brasil e na Espanha apresentam intervalos interquartis de 23,132 W/m<sup>2</sup> (menor que o intervalo do RRE) e de 20,449 W/m<sup>2</sup> (bem próximo do obtido pelo RRE), respectivamente. Aplicado aos dados solares, nas duas localidades, o modelo WD-RNA-RRE conseguiu reduzir os *outliers*. Por meio dos erros dos dados eólicos (50% dos dados) nas previsões eólicas no Brasil e na Espanha, observa-se intervalos interquartis de 0,423 m/s (maior que o intervalo do RRE) e de 0,352 m/s (maior que os intervalos obtidos pelo RRE e PrevTP), respectivamente.

Considerando os resultados obtidos pelo PrevTP, na integração das previsões do recurso solar na Espanha, o modelo obteve RMSE de 26,683 W/m<sup>2</sup>, MAPE de 35,581% e R de 0,998; para o recurso eólico, foi calculado um RMSE de 0,133 m/s, MAPE de 2,060% e R de 0,998. Para a previsão solar no Brasil, foi calculado um RMSE de 48,890 W/m<sup>2</sup>, MAPE de 18,053%

e um R de 0,988; para o recurso eólico, um RMSE de 0,509 m/s, MAPE de 12,820% e um R de 0,977.

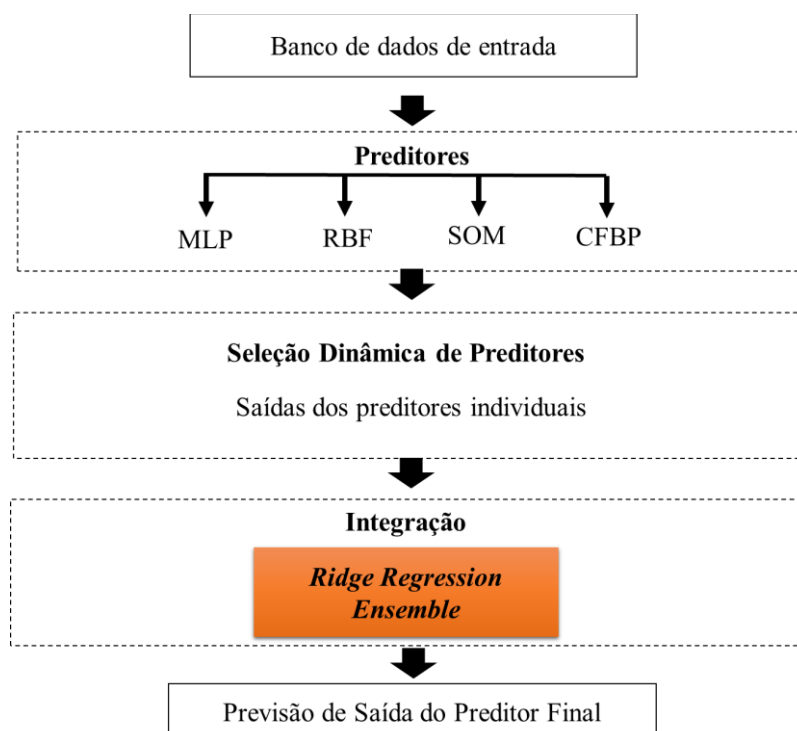
O modelo PrevTP conseguiu superar o RRE e o WD-RNA-RRE apenas na aplicação da integração do recurso eólico na Espanha, mas os modelos RRE e WD-RNA-RRE também obtiveram um bom desempenho e conseguiram melhorar a precisão em relação aos modelos aplicados individualmente. Conseguiu melhorar a precisão dos modelos individuais na aplicação ao recurso solar no Brasil, não sendo superior aos modelos RRE e WD-RNA-RRE. Em termos de MAPE (%), o PrevTP não conseguiu melhorar a precisão das aplicações individuais do recurso eólico no Brasil e do recurso solar na Espanha (nessa aplicação conseguindo reduzir o RMSE e MAE).

Para as aplicações de previsão solar e eólica nas duas localidades, os modelos WD-RNA-RR e o RRE foram capazes de extrair o melhor de cada método de AM e melhorar a precisão dos resultados obtidos pelas quatro técnicas aplicadas individualmente. Assim, esses modelos podem ser ferramentas úteis para melhorar o desempenho de previsões, visando um melhor entendimento do comportamento dos recursos eólicos e solares, auxiliando no gerenciamento de usinas eólicas e solares. As metodologias são estratégias alternativas para gerenciar novas configurações no setor elétrico, com crescente participação de fontes renováveis eólicas e solares.

Por fim, observou-se que metodologias projetadas para integrar e combinar modelos de previsão têm resultados consistentemente melhores do que os melhores modelos aplicados individualmente. As metodologias RRE e WD-RNA-RRE implementadas neste trabalho mostram reduções relevantes nas métricas MAPE, MAE, RMSE e R, quando comparadas às metodologias individuais, confirmando a possibilidade de seu uso para diferentes recursos renováveis intermitentes e locais com diferentes padrões ambientais. Além disso, apresentam desempenhos superiores ou similares, em termos de diferentes métricas, a outras aplicações encontradas na literatura.

## SUGESTÕES PARA TRABALHOS FUTUROS

- Desenvolver modelos *Ensemble* Dinâmicos baseados no *Ridge Regression Ensemble*, podendo a metodologia ser chamada de *Ridge Regression Dynamic Ensemble (RREd)* com estrutura apresentada na Figura abaixo:



- Baseado nas revisões teóricas desenvolvidas nesta Tese, trabalhos futuros podem visar a realização de testes com outras metodologias de decomposição e reconstrução de sinais visando a aplicabilidade na metodologia híbrida aqui desenvolvida.

## ARTIGOS PUBLICADOS VINCULADOS AO PROJETO DE TESE

Durante os quatro anos de pesquisas, artigos científicos relacionados à pesquisa foram publicados em periódicos. Os artigos estão listados abaixo:

### 1. Aplicação PrevTP

Carneiro, T. C., Lima, M.A.F.B., Carvalho, P.C.M., Batista, J.G., Fernández-Ramírez, L. M. Methodology for integration of wind resource forecasts based on artificial neural networks. **International Journal of Energy Research** 2022. <http://doi.org/10.1002/er.7728>.

### 2. Revisão Sistemática

Carneiro, T. C., Carvalho, P. C. M., Santos, H.A., Lima, M. A. F. B., Braga, A. P. D. S. Review on Photovoltaic Power and Solar Resource Forecasting: Current Status and Trends. **Journal of Solar Energy Engineering** 2021, 144(1), 010801. <https://doi.org/10.1115/1.4051652>.

### 3. Aplicação RRE – Solar e Eólica

Carneiro, T. C., Rocha, P. A. C.; Carvalho, P. C. M., Fernández-Ramírez L. M. Ridge regression ensemble of machine learning models applied to solar and wind forecasting in Brazil and Spain. **Applied Energy** 2022, Volume 314, 15 May 2022, 118936. <https://doi.org/10.1016/j.apenergy.2022.118936>.

### 4. Outras publicações

Carvalho, P. C.; Carneiro, T. C. A new methodology to estimate future water-energy nexus based on artificial neural networks. **International Journal of Energy Research** 2021, 45(13), 18670-18683.

Silva, A. W. B., Freitas, B. B., de Alencar Filho, C. L., de Freitas, C. D., de Sousa Junior, E. A., de Castro, E. S., ... & Carneiro, T. C. Methodology Based on Artificial Neural Networks for Hourly Forecasting of PV Plants Generation. **IEEE Latin America Transactions** 2022, 20(4), 659-668.

Reges, J. P., Carvalho, P. C., de Araújo, J. C., Carneiro, T.C. Sizing Methodology of Floating Photovoltaic Plants in Dams of Semi-Arid Areas. **Journal of Solar Energy Engineering** 2022, 144(4), 041003. <https://doi.org/10.1115/1.4052959>.

## REFERÊNCIAS

- ABDEL-NASSER, M.; MAHMOUD, K.; LEHTONEN, M. Reliable Solar Irradiance Forecasting Approach Based on Choquet Integral and Deep LSTMs. **IEEE Transactions on Industrial Informatics**, Vol. 17, No. 3, 2021. Disponível em: <http://dx.doi.org/10.1109/TII.2020.2996235>. Acesso em: 10 jan. 2021.
- ABUELLA, M. CHOWDHURY, B. Forecasting of solar power ramp events: A post-processing approach. **Renewable Energy**, 133:1380e1392, 2019. Disponível em: <https://doi.org/10.1016/j.renene.2018.09.005>. Acesso em: 18 jan. 2020.
- AFRASIABI, M. *et al.* Multi-agent microgrid energy management based on deep learning forecaster. **Energy**, 186:115873, 2019. Disponível em: <https://doi.org/10.1016/j.energy.2019.115873>. Acesso em: 12 jan. 2021.
- AGUIAR, L. M. *et al.* Analysis of satellite derived solar irradiance in islands with site adaptation techniques for improving the uncertainty. **Renewable Energy**, 135:98-107, 2019. Disponível em: <https://doi.org/10.1016/j.renene.2018.11.099>. Acesso em: 14 jan. 2021.
- AGUIAR, L.M. *et al.* Combining solar irradiance measurements, satellite-derived data, and a numerical weather prediction model to improve intra-day solar forecasting. **Renewable Energy**, 97:599-610, 2016. Disponível em: <http://dx.doi.org/10.1016/j.renene.2016.06.018>. Acesso em: 15 jun. 2021.
- AHMAD, M. W.; MOURSHED, M.; REZGUI, Y. Trees vs Neurons: Comparison between random forest and ANN for high-resolution prediction of building energy consumption. **Energy and Buildings**, 147, 77-89, 2017. Disponível em: <http://dx.doi.org/10.1016/j.enbuild.2017.04.038>. Acesso em: 15 jun. 2021.
- AKARSLAN, E.; HOCAOGLU, F.O. A novel method based on similarity for hourly solar irradiance forecasting. **Renewable Energy**, 112:337-346, 2017. Disponível em: <http://dx.doi.org/10.1016/j.renene.2017.05.058>. Acesso em: 10 jan. 2021.
- AKARSLAN, E.; HOCAOGLU, F.O.; EDIZKAN, R. Novel short term solar irradiance forecasting models. **Renewable Energy**, 123:58-66, 2018. Disponível em: <https://doi.org/10.1016/j.renene.2018.02.048>. Acesso em: 15 fev. 2021.
- ALENCAR, C. A.; STEDILE, R.; JUNIOR, J. U. Estudo da Complementariedade da Geração de Energia entre as Fontes Solar e Hidráulica. **Revista Brasileira de Energia Solar**, 9(1), 58-67, 2018. Disponível em: <https://rbens.org.br/rbens/article/view/235>. Acesso em: 20 mar. 2021.
- ALESSANDRINI, S. *et al.* An analog ensemble for short-term probabilistic solar power forecast. **Applied Energy**, 157, 95-110, 2015. Disponível em: <http://dx.doi.org/10.1016/j.apenergy.2015.08.011>. Acesso em: 21 fev. 2021.
- ALFULAYYIH, Y.M.; LI, P.; GWESHA, A.O. A Generic Algorithm for Planning the Year-Round Solar Energy Harvest/Storage to Supply Solar-Based Stable Power. **Journal of Solar**

**Energy Engineering**, Vol. 142 / 041002-1, 2019. Disponível em: <http://dx.doi.org/10.1115/1.4045829>. Acesso em: 15 fev. 2020.

AL-HAJJ, R.; ASSI, A.; FOUAD, M. Short-term prediction of global solar radiation energy using weather data and machine learning ensembles: A comparative study. **Journal of Solar Energy Engineering**, 143(5), 2021. Disponível em: <https://doi.org/10.1115/1.4049624>. Acesso em: 23 abr. 2020.

ALI JALLAL, M. *et al.* AI Data Driven Approach-Based Endogenous Inputs for Global Solar Radiation Forecasting. **Ingénierie des Systèmes d'Information**, 25: 27-34, 2020. Disponível em: <https://doi.org/10.18280/isi.250104>. Acesso em: 14 abr. 2020.

ALI, M. *et al.* Complete ensemble empirical mode decomposition hybridized with random forest and kernel ridge regression model for monthly rainfall forecasts. **Journal of Hydrology**, 584, 124647, 2020. Disponível em: <https://doi.org/10.1016/j.jhydrol.2020.124647>. Acesso em: 04 fev. 2020.

ALONSO-MONTESINOS, J. *et al.* Intra-hour energy potential forecasting in a central solar power plant receiver combining Meteosat images and atmospheric extinction. **Energy**, 188:116034, 2019a. Disponível em: <https://doi.org/10.1016/j.energy.2019.116034>. Acesso em: 22 jun. 2020.

ALONSO-MONTESINOS, J. *et al.* Impact of DNI forecasting on CSP tower plant power production. **Renewable Energy**, 138:368-377, 2019b. Disponível em: <https://doi.org/10.1016/j.renene.2019.01.095>. Acesso em: 12 jul. 2021.

ALTAN, A.; KARASU, S.; ZIO, E. A new hybrid model for wind speed forecasting combining long short-term memory neural network, decomposition methods and grey wolf optimizer. **Applied Soft Computing**, 100, 106996, 2021. Disponível em: <https://doi.org/10.1016/j.asoc.2020.106996>. Acesso em: 12 jul. 2021.

AMARANTE, O. A. C. *et al.* **Atlas do Potencial Eólico Brasileiro**, Brasília, 2001.

AMARO E SILVA, R.; BRITO, M.C. Spatiotemporal PV forecasting sensitivity to modules' tilt and orientation. **Applied Energy**, 255:113807, 2019. Disponível em: <https://doi.org/10.1016/j.apenergy.2019.113807>. Acesso em: 05 mar. 2021.

AMEEN, A. M. *et al.* Modeling and Characterization of a Photovoltaic Array Based on Actual Performance Using Cascade-Forward Back Propagation Artificial Neural Network. **Journal of Solar Energy Engineering**, Vol. 137/041010-1, 2015. Disponível em: <http://dx.doi.org/10.1115/1.4030693>. Acesso em: 15 abr. 2021.

ANAGNOSTOS, D. *et al.* A method for detailed, short-term energy yield forecasting of photovoltaic installations. **Renewable Energy**, 130:122-129, 2019. Disponível em: <https://doi.org/10.1016/j.renene.2018.06.058>. Acesso em: 03 abr. 2020.

ANTONANZAS, J. *et al.* Review of photovoltaic power forecasting. **Solar Energy**, 136:78–111, 2016. Disponível em: <https://doi.org/10.1016/j.solener.2016.06.069>. Acesso em: 13 mai. 2021.

ARYAPUTERA, A.W.; YANG, D.; WALSH, W.M. Day-Ahead Solar Irradiance Forecasting in a Tropical Environment. **Journal of Solar Energy Engineering**, Vol. 137/051009-1, 2015. Disponível em: <http://dx.doi.org/10.1115/1.4030231>. Acesso em: 06 mai. 2020.

ARYAPUTERA, A.W. *et al.* Very short-term irradiance forecasting at unobserved locations using spatiotemporal kriging. **Solar Energy**, 122:1266–1278, 2015. Disponível em: <https://doi.org/10.1016/j.solener.2015.10.023>. Acesso em: 26 mai. 2020.

**ASSOCIAÇÃO BRASILEIRA DE ENERGIA EÓLICA – ABEÓLICA**: Disponível em: <http://www.abeeolica.org.br>. Acesso em: 13 jul. 2023.

**ASSOCIAÇÃO BRASILEIRA DE ENERGIA SOLAR FOTOVOLTAICA – ABSOLAR**: Disponível em: <https://www.absolar.org.br>. Acesso em: 13 jul. 2023.

ATIYA, A. F. Why does forecast combination work so well? **International Journal of Forecasting**, 36(1), 197–200, 2020. Disponível em: <https://doi.org/10.1016/j.ijforecast.2019.03.010>. Acesso em: 10 mai. 2021.

AHMADI, A. *et al.* Long-term wind power forecasting using tree-based learning algorithms. **IEEE Access**, 8, 151511-151522, 2020. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9169867>. Acesso em: 14 abr. 2023.

AHMADI, M.; KHASHEI, M. A fuzzy series-parallel preprocessing (FSPP) based hybrid model for wind forecasting. **IET Generation, Transmission & Distribution**, 16(3), 430-452, 2022. Disponível em: <https://ietresearch-onlinelibrary-wiley.ez11.periodicos.capes.gov.br/doi/epdf/10.1049/gtd2.12291>. Acesso em: 14 jun. 2023.

BABA, N. M. *et al.* Current Issues in Ensemble Methods and Its **Applications**. **Journal of Theoretical & Applied Information Technology**, 81(2), 2015.

BACHER, P.; MADSEN, H.; NIELSEN, H.A. Online short-term solar power forecasting. **Solar Energy**, 83:1772–83, 2009. Disponível em: <https://doi.org/10.1016/j.solener.2009.05.016>. Acesso em: 15 abr. 2020.

BEALE, M.; HAGAN, M.; DEMUTH H. **Neural Network Toolbox 7.0.3: User's Guide**. The MathWorks Inc, Natick, USA, 2012. 404 p.

BENALI, L. *et al.* Solar radiation forecasting using artificial neural network and random forest methods: Application to normal beam, horizontal diffuse and global components. **Renewable Energy**, 132:871-884, 2019. Disponível em: <https://doi.org/10.1016/j.renene.2018.08.044>. Acesso em: 25 abr. 2020.

BIAN, S.; WANG, W. On diversity and accuracy of homogeneous and heterogeneous ensembles. **International Journal of Hybrid Intelligent Systems**, 4(2), 103-128, 2007. Disponível em: <https://doi.org/10.3233/HIS-2007-4204>. Acesso em: 10 fev. 2021.

BIN SHAMS, M. *et al.* Time series analysis of Bahrain's first hybrid renewable energy system. **Energy**, 103:1-15, 2016. Disponível em: <http://dx.doi.org/10.1016/j.energy.2016.02.136>. Acesso em: 21 abr. 2021.



- BOILLEY, A. *et al.* The Solar Forecast Similarity Method: a new method to compute solar radiation forecasts for the next day. **Energy Procedia**, 91:1018–1023, 2016. Disponível em: <https://doi.org/10.1016/j.egypro.2016.06.270>. Acesso em: 12 mai. 2021.
- BOLAND, J.; DAVID, M.; LAURET, P. Short term solar radiation forecasting: Island versus continental sites. **Energy**, 113:186-192, 2016. Disponível em: <http://dx.doi.org/10.1016/j.energy.2016.06.139>. Acesso em: 15 ago. 2020.
- BOUZGOU, H.; GUEYMARD C.A. Fast short-term global solar irradiance forecasting with wrapper mutual information. **Renewable Energy**, 133:1055-1065, 2019. Disponível em: <https://doi.org/10.1016/j.renene.2018.10.096>. Acesso em: 10 ago. 2020.
- BRAGA, A. P.; CARVALHO, A. P. DE L.; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2ª edição, Editora LTC, Rio de Janeiro, 2007. 262 p.
- BREMNES, J. B. Constrained quantile regression splines for ensemble postprocessing. **Monthly Weather Review** 2019, 147(5), 1769-1780. Disponível em: <https://doi.org/10.1175/MWR-D-18-0420.1>. Acesso em: 10 mai. 2021.
- BRITO, N. S. D. *et al.* Aplicação de Redes Neurais Artificiais para Previsão de Carga em Sistemas de Distribuição. **Simpósio Brasileiro de Sistemas Elétricos**, Campina Grande – PB, Brasil, 2006.
- BUENO, A. F. M., BRANDÃO, C. A. L. Visão geral de tecnologia e mercado para os sistemas de armazenamento de energia elétrica no Brasil. **Associação Brasileira de Armazenamento e Qualidade de Energia** 2016. Disponível em: [http://abaque.com.br/wp-content/uploads/2017/07/Estudo\\_Mercado\\_Armazenamento\\_Brasil.pdf](http://abaque.com.br/wp-content/uploads/2017/07/Estudo_Mercado_Armazenamento_Brasil.pdf). Acesso em: 10 mai. 2021.
- BECKER, R. Generation of time-coupled wind power infeed scenarios using pair-copula construction. **IEEE Transactions on Sustainable Energy**, 9(3), 1298-1306, 2018. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8171737>. Acesso em: 14 nov. 2022.
- BENTSEN, L. Ø. *et al.* Spatio-temporal wind speed forecasting using graph networks and novel Transformer architectures. **Applied Energy**, 333, 120565, 2023. Disponível em: <https://doi.org/10.1016/j.apenergy.2022.120565>. Acesso em: 22 mai. 2023.
- CARNEIRO, T. C. *et al.* Review on Photovoltaic Power and Solar Resource Forecasting: Current Status and Trends. **Journal of Solar Energy Engineering**, 144(1), 010801, 2021. Disponível em: <https://doi.org/10.1115/1.4051652>. Acesso em: 15 mai. 2021.
- CARNEIRO, T. C. *et al.* Methodology for integration of wind resource forecasts based on artificial neural networks. **International Journal of Energy Research**, 46(6), 8271-8287, 2022. Disponível em: <https://doi.org/10.1002/er.7728>. Acesso em 10 abr. 2022.
- CARNEIRO, T. C. *et al.* Ridge regression ensemble of machine learning models applied to solar and wind forecasting in Brazil and Spain. **Applied Energy**, Volume 314, 15 May, 118936, 2022. Disponível em: <https://doi.org/10.1016/j.apenergy.2022.118936>. Acesso em: 20 mai. 2022.

CARVALHO, P. C.; CARNEIRO, T. C. A new methodology to estimate future water-energy nexus based on artificial neural networks. **International Journal of Energy Research**, 45(13), 18670-18683, 2021. Disponível em: <https://doi.org/10.1002/er.7009>. Acesso em: 20 mai. 2022.

CAVADOS, G.A. **Análise do Impacto da Introdução das Fontes Intermitentes no Setor Elétrico Brasileiro: Estudo de Caso da Região Nordeste**. 2015. 109 f. Dissertação (Mestrado em Planejamento Energético) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2015. Disponível em: [http://www.ppe.ufrj.br/images/publica%C3%A7%C3%B5es/mestrado/Gabriel\\_de\\_Azevedo\\_Cavados.pdf](http://www.ppe.ufrj.br/images/publica%C3%A7%C3%B5es/mestrado/Gabriel_de_Azevedo_Cavados.pdf). Acesso em: 14 fev. 2020.

CERVONE, G. *et al.* Short-term photovoltaic power forecasting using Artificial Neural Networks and an Analog Ensemble. **Renewable Energy**, 108:274-286, 2017. Disponível em: <http://dx.doi.org/10.1016/j.renene.2017.02.052>. Acesso em: 20 fev 2020.

CHAUDHARY, P.; RIZWAN, M. Energy management supporting high penetration of solar photovoltaic generation for smart grid using solar forecasts and pumped hydro storage system. **Renewable Energy**, 118:928-946, 2018. Disponível em: <https://doi.org/10.1016/j.renene.2017.10.113>. Acesso em: 15 mai. 2021.

CHENG, H. Cloud tracking using clusters of feature points for accurate solar irradiance nowcasting. **Renewable Energy** 2017; 104:281-289. Disponível em: <http://dx.doi.org/10.1016/j.renene.2016.12.023>. Acesso em: 15 mai. 2021

CHENG, H. Hybrid solar irradiance now-casting by fusing Kalman filter and Regressor. **Renewable Energy** 2016; 91:434-441. Disponível em: <http://dx.doi.org/10.1016/j.renene.2016.01.077>. Acesso em: 12 fev. 2020.

CHOW, C.W.; BELONGIE, S.; KLEISSL, J. Cloud motion and stability estimation for intra-hour solar forecasting. **Solar Energy**, 115:645–655, 2015. Disponível em: <http://dx.doi.org/10.1016/j.solener.2015.03.030>. Acesso em: 12 fev. 2020.

CHU, Y.; COIMBRA, C.F.M. Short-term probabilistic forecasts for Direct Normal Irradiance. **Renewable Energy**, 101:526-536, 2017. Disponível em: <http://dx.doi.org/10.1016/j.renene.2016.09.012>. Acesso em: 12 ago. 2020.

CHU, Y. *et al.* Net load forecasts for solar-integrated operational grid feeders. **Solar Energy**, 158:236–246, 2017. Disponível em: <http://dx.doi.org/10.1016/j.solener.2017.09.052>. Acesso em: 12 ago. 2020.

CHU, Y. *et al.* Short-term reforecasting of power output from a 48 MWe solar PV plant. **Solar Energy**, 112:68–77, 2015. Disponível em: <http://dx.doi.org/10.1016/j.solener.2014.11.017>. Acesso em: 20 mai. 2020.

CORNARO, C. *et al.* Twenty-Four Hour Solar Irradiance Forecast Based on Neural Networks and Numerical Weather Prediction. **Journal of Solar Energy Engineering**, Vol. 137/031011-1, 2015. Disponível em: <http://dx.doi.org/10.1115/1.4029452>. Acesso em: 15 ago. 2020.

- CAMELO, H.N. *et al.* A hybrid model based on time series models and neural network for forecasting wind speed in the Brazilian northeast region. **Sustainable Energy Technologies and Assessments**, 28, 65-72, 2018. Disponível em: <https://doi.org/10.1016/j.seta.2018.06.009>. Acesso em: 15 jun. 2023.
- CASCIARO, G. *et al.* Novel strategies of Ensemble Model Output Statistics (EMOS) for calibrating wind speed/power forecasts. **Energy Conversion and Management**, 271, 116297, 2022. Disponível em: <https://doi.org/10.1016/j.enconman.2022.116297>. Acesso em: 20 jan. 2023.
- CHEN, Y. *et al.* Short-term wind speed predicting framework based on EEMD-GA-LSTM method under large scaled wind history. **Energy Conversion and Management**, 227, 113559, 2021. Disponível em: <https://doi.org/10.1016/j.enconman.2020.113559>. Acesso em: 15 abr. 2022.
- CHEN, Y. *et al.* A novel combined model based on echo state network for multi-step ahead wind speed forecasting: A case study of NREL. **Energy conversion and management**, 179, 13-29, 2019. Disponível em: <https://doi.org/10.1016/j.enconman.2018.10.068>. Acesso em: 15 mai. 2023.
- COUTO, A.; ESTANQUEIRO, A. Enhancing wind power forecast accuracy using the weather research and forecasting numerical model-based features and artificial neuronal networks. **Renewable Energy**, 201, 1076-1085, 2022. Disponível em: <https://doi.org/10.1016/j.renene.2022.11.022>. Acesso em: 15 abr. 2023.
- CUI, M. *et al.* A data-driven methodology for probabilistic wind power ramp forecasting. **IEEE Transactions on Smart Grid**, 10(2), 1326-1338, 2019. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8068999>. Acesso em: 21 abr. 2023.
- CUI, Y. *et al.* An algorithm for forecasting day-ahead wind power via novel long short-term memory and wind power ramp events. **Energy**, 263, 125888, 2023. Disponível em: <https://doi.org/10.1016/j.energy.2022.125888>. Acesso em: 23 mai. 2023.
- DAUBECHIES, I. Orthonormal bases of compactly supported wavelets. **Communications on pure and applied mathematics**, 41(7), 909-996, 1988. Disponível em: <https://doi.org/10.1002/cpa.3160410705>. Acesso em: 10 fev. 2022.
- DAUBECHIES, I. The wavelet transform, time-frequency localization and signal analysis. **IEEE transactions on information theory**, 36(5), 961-1005, 1990. Disponível em: <https://ieeexplore.ieee.org/abstract/document/57199>. Acesso em 20 jan. 2022.
- DAWAN, P. *et al.* Comparison of Power Output Forecasting on the Photovoltaic System Using Adaptive Neuro-Fuzzy Inference Systems and Particle Swarm Optimization-Artificial Neural Network Model. **Energies**, 13:351, 2020. Disponível em: <https://doi.org/10.3390/en13020351>. Acesso em: 13 dez. 2020.
- DE CHRISTO, T. M. *et al.* **Wavelets e Redes Neurais Aplicadas A Previsão de Recurso Eólico**. XXI Congresso Brasileiro de Automática, Vitória – Espírito Santo, 2016.
- DE LA ROSA, E. O.; NUÑEZ, G. B.; ROCA, A. O. P.; Ledesma-Alonso R. An Empiric-

Stochastic Approach, Based on Normalization Parameters, to Simulate Solar Irradiance. **Journal of Solar Energy Engineering**, Vol. 141/061011-1, 2019. Disponível em: <http://dx.doi.org/10.1115/1.4043863>. Acesso em: 19 jan. 2020.

DEL CAMPO-AVILA, J. *et al.* A data mining system for predicting solar global spectral irradiance. Performance assessment in the spectral response ranges of thin-film photovoltaic modules. **Renewable Energy**, 133:828-839, 2019. Disponível em: <https://doi.org/10.1016/j.renene.2018.10.083>. Acesso em: 20 ago. 2020.

DEVARAJ, J. *et al.* A holistic review on energy forecasting using big data and deep learning models. **International Journal of Energy Research**, 45 (9):13489-13530, 2021. Disponível em: <https://doi.org/10.1002/er.6679>. Acesso em: 15 fev. 2020.

DONG, J. *et al.* Novel stochastic methods to predict short-term solar radiation and photovoltaic power+. **Renewable Energy**, 145:333-346, 2020. Disponível em: <https://doi.org/10.1016/j.renene.2019.05.073>. Acesso em: 10 jan. 2021.

DONG, Z. *et al.* A novel hybrid approach based on self-organizing maps, support vector regression and particle swarm optimization to forecast solar irradiance. **Energy**, 82:570-577, 2015. Disponível em: <http://dx.doi.org/10.1016/j.energy.2015.01.066>. Acesso em: 13 fev. 2020.

DOUBLEDAY, K. *et al.* Probabilistic Solar Power Forecasting Using Bayesian Model Averaging. **IEEE Transactions on Sustainable Energy**, Vol. 12, No. 1, 2021. Disponível em: <http://dx.doi.org/10.1109/TSTE.2020.2993524>. Acesso em 13 jan. 2022.

ĐOŽIĆ, D. J.; GVOZDENAC, U.B.D. Application of artificial neural networks for testing long-term energy policy targets. **Energy**, 174:488-496, 2019. Disponível em: <https://doi.org/10.1016/j.energy.2019.02.191>. Acesso em: 24 abr. 2020.

DUNLOP, J. Modern Portfolio Theory Meets Wind Farms. **The Journal of Private Equity**, 7(2), 83–95, 2004. Disponível em: <http://www.jstor.org/stable/43503372>. Acesso em: 29 mai. 2020.

DING, M. *et al.* A gated recurrent unit neural networks based wind speed error correction model for short-term wind power forecasting. **Neurocomputing**, 365, 54-61, 2019. Disponível em: <https://doi.org/10.1016/j.neucom.2019.07.058>. Acesso em: 20 jun. 2022.

DU, P. *et al.* A novel hybrid model for short-term wind power forecasting. **Applied Soft Computing**, 80, 93-106, 2019. Disponível em: <https://doi.org/10.1016/j.asoc.2019.03.035>. Acesso em: 18 mai. 2022.

DUAN, J. *et al.* A combined short-term wind speed forecasting model based on CNN–RNN and linear regression optimization considering error. **Renewable Energy**, 200, 788-808, 2022. Disponível em: <https://doi.org/10.1016/j.renene.2022.09.114>. Acesso em: 14 nov. 2022.

ESEYE, A.T. *et al.* Adaptive Predictor Subset Selection Strategy for Enhanced Forecasting of Distributed PV Power Generation. **IEEE Access**, 7, 90652-90665, 2019. Disponível em: <https://doi.org/10.1109/ACCESS.2019.2926826>. Acesso em: 20 jun. 2020.

EZZAT, A. A.; JUN, M.; DING, Y. Spatio-temporal short-term wind forecast: A calibrated regime-switching method. **The annals of applied statistics**, 13(3), 1484, 2019. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7422960/>. Acesso em: 15 fev. 2023.

EZZAT, A.A.; JUN, M.; DING, Y. Spatio-temporal asymmetry of local wind fields and its impact on short-term wind forecasting. **IEEE transactions on sustainable energy**, 9(3), 1437-1447, 2018. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8246533>. Acesso em: 13 dez. 2022.

Facto Energy/GIZ, Benchmarking Internacional — **Expansão da Geração de Energia Elétrica a partir de Fontes Renováveis**, 2018. Disponível em: [http://factoenergy.com/servicos\\_desc.php?uid=5](http://factoenergy.com/servicos_desc.php?uid=5). Acesso em: 14 dez. 2020.

FARIAS, C. A. S. *et al.* Kohonen Neural Networks for Rainfall-runoff Modeling: Case Study of Piancó River Basin, **Journal of Urban and Environmental Engineering**, v.7, n.1, p.176-182, 2013. Disponível em: <https://www.jstor.org/stable/26203402>. Acesso em: 23 fev. 2020.

FATEMI, S.A., KUH, A., FRIPP, M. Parametric methods for probabilistic forecasting of solar irradiance. **Renewable Energy**, 129:666-676, 2018. Disponível em: <https://doi.org/10.1016/j.renene.2018.06.022>. Acesso em: 10 mai. 2020.

FEN, L. *et al.* A Novel Model for Daily Energy Production Estimation of Grid-Connected Photovoltaic System. **Journal of Solar Energy Engineering**, Vol. 137 / 031013-1, 2015. Disponível em: <http://dx.doi.org/10.1115/1.4029454>. Acesso em: 23 fev. 2021.

FOUILLOY, A. *et al.* Solar irradiation prediction with machine learning: Forecasting models selection method depending on weather variability. **Energy**, 165:620-629, 2018. Disponível em: <https://doi.org/10.1016/j.energy.2018.09.116>. Acesso em: 25 jul. 2021.

GAO, M. *et al.* Day-ahead power forecasting in a large-scale photovoltaic plant based on weather classification using LSTM. **Energy**, 187: 115838, 2019. Disponível em: <https://doi.org/10.1016/j.energy.2019.07.168>. Acesso em: 20 mar. 2020.

GARCÍA-HINDE, O. *et al.* Evaluation of dimensionality reduction methods applied to numerical weather models for solar radiation forecasting. **Engineering Applications of Artificial Intelligence**, 69:157–167, 2018. Disponível em: <https://doi.org/10.1016/j.engappai.2017.12.003>. Acesso em: 10 mar. 2021.

GHIMIRE, S. *et al.* Deep solar radiation forecasting with convolutional neural network and long short-term memory network algorithms. **Applied Energy**, 253:113541, 2019. Disponível em: <https://doi.org/10.1016/j.apenergy.2019.113541>. Acesso em: 16 ago. 2020.

GIAMMANCO, C. *et al.* Statistic Determination of Storage Capacity for Photovoltaic Energy Imbalance Mitigation. **Journal of Solar Energy Engineering**, Vol. 138 / 011002-1, 2016. Disponível em: <http://dx.doi.org/10.1115/1.4031801>. Acesso em: 15 jun. 2021.

GUERMOUI, M. *et al.* A Novel Hybrid Model for Solar Radiation Forecasting Using Support Vector Machine and Bee Colony Optimization Algorithm: Review and Case Study. **Journal of Solar Energy Engineering**, Vol. 143 / 020801-1, 2020. Disponível em: <http://dx.doi.org/10.1115/1.4047852>. Acesso em: 15 jan. 2021.

GUERMOUI, M.; MELGANI, F.; DANILO, C. Multi-step ahead forecasting of daily global and direct solar radiation: A review and case study of Ghardaia region. **Journal of Cleaner Production**, 201:716-734, 2018. Disponível em: <https://doi.org/10.1016/j.jclepro.2018.08.006>. Acesso em: 20 jun. 2020.

GILBERT, C.; BROWELL, J.; MCMILLAN, D. Leveraging turbine-level data for improved probabilistic wind power forecasting. **IEEE Transactions on Sustainable Energy**, 11(3), 1152-1160, 2019. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8732463>. Acesso em: 10 mai. 2022.

GOMES, L. E. *et al.* Space–time calibration of wind speed forecasts from regional climate models. **Environmental and Ecological Statistics**, 28(3), 631-665, 2021. Disponível em: <https://link.springer.com/article/10.1007/s10651-021-00509-0>. Acesso em: 15 jun. 2022.

GOUTHAM, N. *et al.* Using machine-learning methods to improve surface wind speed from the outputs of a numerical weather prediction model. **Boundary-Layer Meteorology**, 179, 133-161, 2021. Disponível em: <https://link.springer.com/article/10.1007/s10546-020-00586-x>. Acesso em: 23 out. 2022.

GU, B. *et al.* Short-term wind power forecasting and uncertainty analysis based on FCM–WOA–ELM–GMM. **Energy Reports**, 9, 807-819, 2023. Disponível em: <https://doi.org/10.1016/j.egy.2022.11.202>. Acesso em: 10 mai. 2023.

HAN, Y. *et al.* A PV power interval forecasting based on seasonal model and nonparametric estimation algorithm. **Solar Energy**, 184:515–526, 2019. Disponível em: <https://doi.org/10.1016/j.solener.2019.04.025>. Acesso em: 15 jun. 2021.

HAYKIN, S. **Neural Networks: a Comprehensive Foundation**, 2 ed., Prentice Hall, Upper Saddle River, USA, 1999.

HEO, J. *et al.* Digital elevation model-based convolutional neural network modeling for searching of high solar energy regions. **Applied Energy**, 262:114588, 2020. Disponível em: <https://doi.org/10.1016/j.apenergy.2020.114588>. Acesso em: 10 nov. 2021.

HEYDARI, A. *et al.* A novel composite neural network-based method for wind and solar power forecasting in microgrids. **Applied Energy**, 251:113353, 2019. Disponível em: <https://doi.org/10.1016/j.apenergy.2019.113353>. Acesso em: 13 mar. 2021.

HOCAOGLU, F.O.; SERTTAS, F. A novel hybrid (Mycielski-Markov) model for hourly solar radiation forecasting. **Renewable Energy**, 108:635-643, 2017. Disponível em: <http://dx.doi.org/10.1016/j.renene.2016.08.058>. Acesso em: 20 mai. 2020.

HODGE, B. M. *et al.* The combined value of wind and solar power forecasting improvements and electricity storage. **Applied Energy**, 214, 1-15, 2018. Disponível em: <https://doi.org/10.1016/j.apenergy.2017.12.120>. Acesso em: 20 jun. 2021.

HOERL, A.E.; KENNARD, R.W. Ridge Regression: Biased Estimation for Nonorthogonal Problems, **Technometrics**, 12:1, 55-67, 1970. Disponível em: <https://doi.org/10.1080/00401706.1970.10488634>. Acesso em: 03 mai. 2020.

HONG, Y.; MARTINEZ, J.J.F.; FAJARDO, A.C. Day-Ahead Solar Irradiation Forecasting Utilizing Gramian Angular Field and Convolutional Long Short-Term Memory. **IEEE Access**, 8, 18741-18753, 2020. Disponível em; <https://doi.org/10.1109/ACCESS.2020.2967900>. Acesso em: 15 fev. 2021.

HONG, J.; WU, Y. A literature review of wind forecasting technology in the world, **IEEE Power Tech**, pp. 504-509, 2007. Disponível em: <https://ieeexplore.ieee.org/abstract/document/4538368>. Acesso em 20 mar. 2020.

HOSSAIN, M. *et al.* Application of extreme learning machine for short term output power forecasting of three grid-connected PV systems. **Journal of Cleaner Production**, 167:395-405, 2017. Disponível em: <http://dx.doi.org/10.1016/j.jclepro.2017.08.081>. Acesso em: 26 abr. 2020.

HU, K. *et al.* A new ultra-short-term photovoltaic power prediction model based on ground-based cloud images. **Journal of Cleaner Production**, 200:731-745, 2018. Disponível em: <https://doi.org/10.1016/j.jclepro.2018.07.311>. Acesso em: 20 fev. 2021.

HUANG, R. *et al.* Solar generation prediction using the ARMA model in a laboratory-level micro-grid. **IEEE Third International Conference on Smart Grid Communications**, p. 528–33, 2012. Disponível em: <https://ieeexplore.ieee.org/abstract/document/6486039>. Acesso em 28 mai. 2021.

HUSSAIN, S.; ALALILI, A. Online Sequential Learning of Neural Networks in Solar Radiation Modeling Using Hybrid Bayesian Hierarchical Approach. **Journal of Solar Energy Engineering**, Vol. 138 / 061012-1, 2016. Disponível em: <http://dx.doi.org/10.1115/1.4034907>. Acesso em: 10 mai. 2021.

HUVA, R.; VERBOIS, H.; WALSH, W. Comparisons of next-day solar forecasting for Singapore using 3DVAR and 4DVAR data assimilation approaches with the WRF model. **Renewable Energy**, 147:663-671, 2020. Disponível em: <https://doi.org/10.1016/j.renene.2019.09.011>. Acesso em: 14 fev. 2021.

HOLOHAN, V.; TOMLIN, A. S.; COCKERILL, T. Improved near surface wind speed predictions using Gaussian process regression combined with numerical weather predictions and observed meteorological data. **Renewable Energy**, 126, 1043-1054, 2018. Disponível em: <https://doi.org/10.1016/j.renene.2018.04.019>. Acesso em: 10 abr. 2020.

HU, J. *et al.* Deterministic and probabilistic wind speed forecasting with de-noising-reconstruction strategy and quantile regression based algorithm. **Renewable Energy**, 162, 1208-1226, 2020. Disponível em: <https://doi.org/10.1016/j.renene.2020.08.077>. Acesso em: 24 abr. 2023.

Hu, Y. L.; Chen, L. A nonlinear hybrid wind speed forecasting model using LSTM network, hysteretic ELM and Differential Evolution algorithm. **Energy conversion and management**, 173, 123-142, 2018. Disponível em: <https://doi.org/10.1016/j.enconman.2018.07.070>. Acesso em: 18 jun. 2023.

HAESSIG, P. *et al.* Energy storage sizing for wind power: impact of the autocorrelation of day-ahead forecast errors. **Wind Energy**, 18:43–57, 2015. Disponível em: <https://doi.org/10.1002/we.1680>. Acesso em: 23 jan. 2021.

INAGE, S. Development of an advection model for solar forecasting based on ground data first report: Development and verification of a fundamental model. **Solar Energy**, 153:414–434, 2017. Disponível em: <http://dx.doi.org/10.1016/j.solener.2017.05.019>. Acesso em: 15 mai. 2020.

JAMAL, T. *et al.* An energy flow simulation tool for incorporating short-term PV forecasting in a diesel-PV-battery off-grid power supply system. **Applied Energy**, 254:113718, 2019. Disponível em: <https://doi.org/10.1016/j.apenergy.2019.113718>. Acesso em: 20 fev. 2020.

JAMES, G. *et al.* **An introduction to statistical learning**, Vol. 112. New York: springer. 2013. p. 18

JIANG, H. *et al.* Intelligent optimization models based on hard-ridge penalty and RBF for forecasting global solar radiation. **Energy Conversion and Management**, 95, 42-58, 2015. Disponível em: <https://doi.org/10.1016/j.enconman.2015.02.020>. Acesso em: 12 mai. 2020.

JUNG, Y. *et al.* Long short-term memory recurrent neural network for modeling temporal patterns in long-term power forecasting for solar PV facilities: Case study of South Korea. **Journal of Cleaner Production**, 250, 119476, 2020. Disponível em: <https://doi.org/10.1016/j.jclepro.2019.119476>. Acesso em: 15 abr. 2021.

JIANG, Y. *et al.* A novel wind speed prediction method: Hybrid of correlation-aided DWT, LSSVM and GARCH. **Journal of Wind Engineering and Industrial Aerodynamics**, 174, 28-38, 2018. Disponível em: <https://doi.org/10.1016/j.jweia.2017.12.019>. Acesso em: 15 mai. 2023.

JIANG, Z. *et al.* A CGRU multi-step wind speed forecasting model based on multi-label specific XGBoost feature selection and secondary decomposition. **Renewable Energy**, 203, 802-827, 2023. Disponível em: <https://doi.org/10.1016/j.renene.2022.12.124>. Acesso em: 25 mai. 2023.

JOSEPH, L.P. *et al.* Near real-time wind speed forecast model with bidirectional LSTM networks. **Renewable Energy**, 204, 39–58, 2023. Disponível em: <https://doi.org/10.1016/j.renene.2022.12.123>. Acesso em: 25 mai. 2023.

KABOURIS, J.; KANELLOS, F.D. Impacts of large-scale wind penetration on designing and operation of electric power systems, Sustain. **IEEE Transactions on sustainable energy**, 1 (2);107,114, 2010. Disponível em: <https://ieeexplore.ieee.org/abstract/document/5466194>. Acesso em: 10 mai. 2020.

KAMADINATA, J. O.; KEN, T. L.; SUWA, T. Solar Irradiance Fluctuation Prediction Methodology Using Artificial Neural Networks. **Journal of Solar Energy Engineering**, Vol. 142 / 031003-1, 2020. Disponível em: <http://dx.doi.org/10.1115/1.404531>. Acesso em: 15 fev. 2021.

KARASU, S. *et al.* Prediction of solar radiation based on machine learning methods. **Journal**



- of **cognitive systems**, 2(1), 16-20, 2017. Disponível em: <https://dergipark.org.tr/en/pub/jcs/issue/33186/390233>. Acesso em: 20 fev. 2021.
- KARASU, S.; ALTAN, A. Recognition model for solar radiation time series based on random forest with feature selection approach. In: **2019 11th international conference on electrical and electronics engineering (ELECO)**. IEEE, Bursa, Turkey, p. 8-11, 2019. Bursa, Turkey, 2019, pp. 8-11, DOI: 10.23919/ELECO47770.2019.8990664. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8990664>. Acesso em: 15 fev. 2021.
- KAUR, A. *et al.* Benefits of solar forecasting for energy imbalance markets. **Renewable Energy**, 86:819-830, 2016. Disponível em: <http://dx.doi.org/10.1016/j.renene.2015.09.011>. Acesso em: 10 mai. 2020.
- KITCHENHAM, B.; CHARTERS, S. **Guidelines for performing Systematic Literature Reviews in Software Engineering, Technical Report EBSE-2007-01**, Department of Computer Science, University of Durham, Durham, UK, 2007.
- KONSTANTINOV, A.V.; UTKIN, L.V. **Interpretable machine learning with an ensemble of gradient boosting machines**. Knowledge-Based Systems, Volume 222, 2021, 106993, 2021, ISSN 0950-7051. Disponível em: <https://doi.org/10.1016/j.knosys.2021.106993>. Acesso em: 12 jan. 2022.
- KUMAR DAS, U. *et al.* A. Forecasting of photovoltaic power generation and model optimization: A review. **Renewable and Sustainable Energy Reviews**, 81: 912–928, 2018. Disponível em: <http://dx.doi.org/10.1016/j.rser.2017.08.017>. Acesso em: 25 fev. 2020.
- KURTZ, B.; MEJIA, F.; KLEISSL, J. A virtual sky imager testbed for solar energy forecasting. **Solar Energy**, 158:753–759, 2017. Disponível em: <http://dx.doi.org/10.1016/j.solener.2017.10.036>. Acesso em: 30 abr. 2021.
- KUSHWAHA, V.; PINDORIYA, N.M. A SARIMA-RVFL hybrid model assisted by wavelet decomposition for very short-term solar PV power generation forecast. **Renewable Energy**, 140:124-139, 2019. Disponível em: <https://doi.org/10.1016/j.renene.2019.03.020>. Acesso em: 10 fev. 2020.
- KIM, D.; HUR, J. Short-term probabilistic forecasting of wind energy resources using the enhanced ensemble method. **Energy**, 157, 211-226, 2018. Disponível em: <https://doi.org/10.1016/j.energy.2018.05.157>. Acesso em: 18 jun. 2023.
- LAN, H. *et al.* Day-ahead spatio-temporal forecasting of solar irradiation along a navigation route. **Applied Energy**, 211:15–27, 2018. Disponível em: <https://doi.org/10.1016/j.apenergy.2017.11.014>. Acesso em: 15 mar. 2021.
- LAN, H. *et al.* Day-ahead spatiotemporal solar irradiation forecasting using frequency-based hybrid principal component analysis and neural network. **Applied Energy**, 247:389–402, 2019. Disponível em: <https://doi.org/10.1016/j.apenergy.2019.04.056>. Acesso em: 20 fev. 2021.
- LARSON, D.P. ; NONNENMACHER, L.; COIMBRA, C.F.M. 2016. Day-ahead forecasting of solar power output from photovoltaic plants in the American Southwest. **Renewable**

**Energy**, 91:11-20, 2016. Disponível em: <http://dx.doi.org/10.1016/j.renene.2016.01.039>. Acesso em: 09 fev. 2020.

LAURET, P. *et al.* Characterization of the intraday variability regime of solar irradiation of climatically distinct locations. **Solar Energy**, 125:99–110, 2016. Disponível em: <http://dx.doi.org/10.1016/j.solener.2015.11.032>. Acesso em: 12 mai. 2021.

LI, J. *et al.* Machine learning for solar irradiance forecasting of photovoltaic system. **Renewable Energy**, 90:542-553, 2016. Disponível em: <http://dx.doi.org/10.1016/j.renene.2015.12.069>. Acesso em: 20 jul. 2020.

LI, P. *et al.* Daily Surface Solar Radiation Prediction Mapping Using Artificial Neural Network: The Case Study of Reunion Island. **Journal of Solar Energy Engineering**, Vol. 142/021009-1, 2020. Disponível em: <http://dx.doi.org/10.1115/1.4045274>. Acesso em: 11 mai. 2021.

LI, S.; WANG, P.; GOEL, L. Short-term load forecasting by wavelet transform and evolutionary extreme learning machine. **Electric Power Systems Research**, 122, 96-103, 2015. Disponível em: <https://doi.org/10.1016/j.epsr.2015.01.002>. Acesso em: 15 mai. 2020.

LIMA, F. J. L. *et al.* Forecast for surface solar irradiance at the Brazilian Northeastern region using NWP model and artificial neural networks. **Renewable Energy**, 87:807-818, 2016. Disponível em: <http://dx.doi.org/10.1016/j.renene.2015.11.005>. Acesso em: 20 fev. 2021.

LIMA, M.A.F.B. *et al.* Improving solar forecasting using Deep Learning and Portfolio Theory integration. **Energy** 195:117016, 2020. Disponível em: <https://doi.org/10.1016/j.energy.2020.117016>. Acesso em: 15 fev. 2021.

LIMA, M. A. F. B. **Técnicas de previsão do recurso solar integradas a partir da teoria do portfólio**. 2020. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal do Ceará, Fortaleza, 2020. Disponível em: <https://repositorio.ufc.br/handle/riufc/52896>. Acesso em: 14 mai. 2021.

LIU, C. *et al.* Fuzzy energy and reserve co-optimization with high penetration of renewable energy. **IEEE Trans. Sustain. Energy**, 8(2), 782–791, 2017. Disponível em: <https://ieeexplore.ieee.org/abstract/document/7605447>. Acesso em: 26 mai. 2020.

LIU, D.; SUN, K. Random Forest solar power forecast based on classification Optimization. **Energy**, 187:115940, 2019. Disponível em: <https://doi.org/10.1016/j.energy.2019.115940>. Acesso em: 15 fev. 2021.

LIU, H. *et al.* Deterministic wind energy forecasting: A review of intelligent predictors and auxiliary methods. **Energy Conversion and Management**. 195: 328–345, 2019a. Disponível em: <https://doi.org/10.1016/j.enconman.2019.05.020>. Acesso em: 02 jun. 2020.

LIU, J.; WANG, X.; LU, Y. A novel hybrid methodology for short-term wind power forecasting based on adaptive neuro-fuzzy inference system. **Renewable Energy**. 103: 620-629, 2017. Disponível em: <http://dx.doi.org/10.1016/j.renene.2016.10.074>. Acesso em: 15 abr. 2020.

- LIU, P. *et al.* PEV charging coordination to absorb excess wind energy via group differentiated dual-tariff schemes. **Electric Power Systems Research**, 151, 208-217, 2017. Disponível em: <https://doi.org/10.1016/j.epsr.2017.05.033>. Acesso em: 10 jun. 2021.
- LIU, Y. *et al.* Ensemble spatiotemporal forecasting of solar irradiation using variational Bayesian convolutional gate recurrent unit network. **Applied Energy**, 253:113596, 2019b. Acesso em: <https://doi.org/10.1016/j.apenergy.2019.113596>. Acesso em: 05 jan. 2020.
- LIU, Z. *et al.* Prediction short-term photovoltaic power using improved chicken swarm optimizer - Extreme learning machine model. **Journal of Cleaner Production**, 248:119272, 2020b. Disponível em: <https://doi.org/10.1016/j.jclepro.2019.119272>. Acesso em: 11 mai. 2021.
- LIU, C. *et al.* An Improved Anticancer Drug-Response Prediction Based on an Ensemble Method Integrating Matrix Completion and Ridge Regression. **Molecular Therapy-Nucleic Acids**, 21, 676-686 2020c. Disponível em: <https://doi.org/10.1016/j.omtn.2020.07.003>. Acesso em: 09 abr. 2021.
- LIU, Z. *et al.* A combined forecasting model for time series: Application to short-term wind speed forecasting. **Applied Energy**, 259, 114137, 2020a. Disponível em: <https://doi.org/10.1016/j.apenergy.2019.114137>. Acesso em: 11 jul. 2020.
- LIVIERIS, I. E. *et al.* Ensemble deep learning models for forecasting cryptocurrency time-series. **Algorithms**, 13(5), 121, 2020. Disponível em: <https://doi.org/10.3390/a13050121>. Acesso em: 12 fev. 2020.
- LEE, D.; SHIN, H.; BALDICK, R. Bivariate probabilistic wind power and real-time price forecasting and their applications to wind power bidding strategy development. **IEEE Transactions on Power Systems**, 33(6), 6087-6097, 2018. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8352041>. Acesso em: 15 dez. 2022.
- LEE, D.Y. *et al.* Multi-model seasonal forecasts for the wind energy sector. **Climate Dynamics**, 53, 2715-2729, 2019. Disponível em: <https://link.springer.com/article/10.1007/s00382-019-04654-y>. Acesso em: 12 ago. 2022.
- LI, J. *et al.* Forecasting of wind capacity ramp events using typical event clustering identification. **IEEE Access**, 8, 176530-176539, 2020a. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9205917>. Acesso em: 13 fev. 2023.
- LI, L.L. *et al.* Improving short-term wind power prediction using hybrid improved cuckoo search arithmetic-support vector regression machine. **Journal of Cleaner Production**, 279, 123739, 2021. Disponível em: <https://doi.org/10.1016/j.jclepro.2020.123739>. Acesso em: 13 jul. 2022.
- LI, L.L. *et al.* Wind power prediction using a novel model on wavelet decomposition-support vector machines-improved atomic search algorithm. **Journal of Cleaner Production**, 270, 121817, 2020a. Disponível em: <https://doi.org/10.1016/j.jclepro.2020.121817>. Acesso em: 14 out. 2022.

- LI, M. *et al.* A wind speed correction method based on modified hidden Markov model for enhancing wind power forecast. **IEEE Transactions on Industry Applications**, 58(1), 656-666, 2021a. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9611028>. Acesso em: 12 abr. 2023.
- LI, R.; JIN, Y. A wind speed interval prediction system based on multi-objective optimization for machine learning method. **Applied Energy**, 228, 2207-2220, 2018. Disponível em: <https://doi.org/10.1016/j.apenergy.2018.07.032>. Acesso em: 14 jun. 2023.
- LI, Y. *et al.* Multi-step ahead wind speed forecasting approach coupling maximal overlap discrete wavelet transform, improved grey wolf optimization algorithm and long short-term memory. **Renewable Energy**, 196, 1115-1126, 2022. Disponível em: <https://doi.org/10.1016/j.renene.2022.07.016>. Acesso em: 10 ago. 2022.
- LI, Y.; WU, H.; LIU, H. Multi-step wind speed forecasting using EWT decomposition, LSTM principal computing, RELM subordinate computing and IEWT reconstruction. **Energy Conversion and Management**, 167, 203-219, 2018. Disponível em: <https://doi.org/10.1016/j.enconman.2018.04.082>. Acesso em: 10 abr. 2023.
- LIU, H.; CHEN, C. Data processing strategies in wind energy forecasting models and applications: A comprehensive review. **Applied Energy**, 249, 392-408, 2019. Disponível em: <https://doi.org/10.1016/j.apenergy.2019.04.188>. Acesso em: 08 fev. 2023.
- LIU, H. *et al.* Big multi-step wind speed forecasting model based on secondary decomposition, ensemble method and error correction algorithm. **Energy Conversion and Management**, 156, 525-541, 2018. Disponível em: <https://doi.org/10.1016/j.enconman.2017.11.049>. Acesso em: 10 mai. 2023.
- LIU, H.; WU, H.; LI, Y. Smart wind speed forecasting using EWT decomposition, GWO evolutionary optimization, RELM learning and IEWT reconstruction. **Energy Conversion and Management**, 161, 266-283, 2019. Disponível em: <https://doi.org/10.1016/j.enconman.2018.02.006>. Acesso em: 15 jun. 2023.
- LIU, L. *et al.* Ultra-short-term wind power forecasting based on deep Bayesian model with uncertainty. **Renewable Energy**, 205, 598-607, 2023. Disponível em: <https://doi.org/10.1016/j.renene.2023.01.038>. Acesso em: 30 mai. 2023.
- LEE, K. Y.; VALE, Z. A. (Eds.). Applications of modern heuristic optimization methods in power and energy systems. John Wiley & Sons. Hoboken, New Jersey, 2020.
- MALEKI, A.; KHAJEH, M.G.; ROSEN, M.A. Weather forecasting for optimization of a hybrid solar-wind-powered reverse osmosis water desalination system using a novel optimizer approach. **Energy**, 114:1120-1134, 2016. Disponível em: <http://dx.doi.org/10.1016/j.energy.2016.06.134>. Acesso em: 14 mai. 2021.
- MALLAT, S.G. A theory for multiresolution signal decomposition: the wavelet representation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, vol. 11, no. 7, pp. 674-693, 1989. Disponível em: <http://dx.doi.org/10.1109/34.192463>. Acesso em: 10 out. 2021.

- MANDAL, P. *et al.* A novel hybrid approach using wavelet, firefly algorithm, and fuzzy ARTMAP for day-ahead electricity price forecasting. **IEEE Transactions on Power Systems**, 28(2), 1041-1051, 2013. Disponível em: <https://ieeexplore.ieee.org/abstract/document/6353241>. Acesso em: 15 out. 2020.
- MARKOWITZ, H.M. '*Portfolio selection – efficient diversification of investments*'. 2. ed. Auflage, 1992.
- MARKOWITZ, H.M. '*Portfolio selection: efficient diversification of investments*'. 1. ed. John Wiley & Sons, 1956.
- MATHIESEN, P.; KLEISSL, J. Evaluation of numerical weather prediction for intra-day solar forecasting in the continental United States. **Solar Energy**, 85:967–77, 2011. Disponível em: <https://doi.org/10.1016/j.solener.2011.02.013>. Acesso em 12 nov. 2020.
- MCCANDLESS, T.C.; HAUPT, S.E.; YOUNG, G.S. A regime-dependent artificial neural network technique for shortrange solar irradiance forecasting. **Renewable Energy**, 89:351-359, 2016. Disponível em: <http://dx.doi.org/10.1016/j.renene.2015.12.030>. Acesso em: 15 dez. 2020.
- MELO, M.P.S, **Modelo híbrido inteligente baseado em filtragem wavelet e redes neurais com aplicações à previsão de séries temporais**. 2018. Tese (Tese de doutorado). Universidade Federal Rural de Pernambuco, Biometria e estatística aplicada, 2018. Disponível em: [http://www.ppgbea.ufrpe.br/sites/www.ppgbea.ufrpe.br/files/documentos/tese\\_milton\\_perceus\\_santos\\_de\\_melo.pdf](http://www.ppgbea.ufrpe.br/sites/www.ppgbea.ufrpe.br/files/documentos/tese_milton_perceus_santos_de_melo.pdf). Acesso em: 30 mar. 2021.
- MENDES-MOREIRA, J.A. *et al.* Ensemble approaches for regression: a survey, **ACM Comput. Surv**, 45 (1):1–40, 2012. Disponível em: <https://doi.org/10.1145/2379776.2379786>. Acesso em: 15 abr. 2021.
- MERT YAGLI, G.; YANG, D.; SRINIVASAN, D. Automatic hourly solar forecasting using machine learning models. **Renewable and Sustainable Energy Reviews**, 105:487–498, 2019. Disponível em: <https://doi.org/10.1016/j.rser.2019.02.006>. Acesso em: 19 mai. 2021.
- MERTYAGLI, G. *et al.* Can we justify producing univariate machine-learning forecasts with satellite-derived solar irradiance? **Applied Energy**, 259:114122, 2020. Disponível em: <https://doi.org/10.1016/j.apenergy.2019.114122>. Acesso em: 28 abr. 2021.
- MILLER, S.D. *et al.* Short-term solar irradiance forecasting via satellite/model coupling. **Solar Energy**, 168:102–117, 2018. Disponível em: <https://doi.org/10.1016/j.solener.2017.11.049>. Acesso em: 15 out. 2020.
- MONJOLY, S. *et al.* Hourly forecasting of global solar radiation based on multiscale decomposition methods: A hybrid approach. **Energy**, 119:288-298, 2017. Disponível em: <http://dx.doi.org/10.1016/j.energy.2016.11.061>. Acesso em: 04 ago. 2021.
- MURATA, A.; OHTAKE, H.; OOZEKI, T. Modeling of uncertainty of solar irradiance forecasts on numerical weather predictions with the estimation of multiple confidence intervals. **Renewable Energy**, 117:193-201, 2018. Disponível em:

<https://doi.org/10.1016/j.renene.2017.10.043>. Acesso em: 14 nov. 2020.

NAM, S.; HUR, J. A hybrid spatiotemporal forecasting of solar generating resources for grid integration. **Energy**, 177:503-510, 2019. Disponível em: <https://doi.org/10.1016/j.energy.2019.04.127>. Acesso em: 10 abr. 2021.

MARARAKANYE, N.; DALTON, A.; BEKKER, B. Incorporating Spatial and Temporal Correlations to Improve Aggregation of Decentralized Day-Ahead Wind Power Forecasts. **IEEE Access**, 10, 116182-116195, 2022. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9938983>. Acesso em: 12 mai. 2022.

MASTRANTONIO, G.; POLLICE, A.; FEDELE, F. Distributions-oriented wind forecast verification by a hidden Markov model for multivariate circular-linear data. **Stochastic environmental research and risk assessment**, 32, 169-181, 2018. Disponível em <https://link.springer.com/article/10.1007/s00477-017-1416-x>. Acesso em: 08 mai. 2022.

MEDINA, S.V.; AJENJO, U. P. Performance improvement of artificial neural network model in short-term forecasting of wind farm power output. **Journal of Modern Power Systems and Clean Energy**, 8(3), 484-490, 2020. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9082068>. Acesso em: 20 jul. 2022.

MEHDIZADEH, S.; KOZEKALANI SALES, A.; SAFARI, M. J. S. Estimating the short-term and long-term wind speeds: implementing hybrid models through coupling machine learning and linear time series models. **SN Applied Sciences**, 2, 1-15, 2020. Disponível em: <https://link.springer.com/article/10.1007/s42452-020-2830-0>. Acesso em: 25 ago. 2022.

MESSNER, J.W. *et al.* Evaluation of wind power forecasts - An up-to-date view. **Wind Energy**; 23: 1461– 1481, 2020. Disponível em: <https://doi.org/10.1002/we.2497>. Acesso em: 15 fev. 2023.

MI, X.; LIU, H.; LI, Y. Wind speed prediction model using singular spectrum analysis, empirical mode decomposition and convolutional support vector machine. **Energy conversion and management**, 180, 196-205, 2019. Disponível em: <https://doi.org/10.1016/j.enconman.2018.11.006>. Acesso em: 0

MÖHRLÉN, C. *et al.* How do humans decide under wind power forecast uncertainty—an IEA Wind Task 36 probabilistic forecast games and experiments initiative. **Journal of Physics: Conference Series** (Vol. 2151, No. 1, p. 012014). IOP Publishing, 2022. Disponível em: <https://iopscience.iop.org/article/10.1088/1742-6596/2151/1/012014/meta>. Acesso em: 15 fev. 2023.

NEIVA, A. *et al.* **Atlas do Potencial Eólico Brasileiro**. Rio de Janeiro: CEPREL, 2017.

NESPOLI, A. *et al.* Machine Learning techniques for solar irradiation nowcasting: Cloud type classification forecast through satellite data and imagery. **Applied Energy**, 305, 117834, 2022. Disponível em: <https://doi.org/10.1016/j.apenergy.2021.117834>. Acesso em: 03 abr. 2021.

NI, Q. *et al.* An ensemble prediction intervals approach for short-term PV power forecasting. **Solar Energy**, 155:1072–1083, 2017. Disponível em:

<http://dx.doi.org/10.1016/j.solener.2017.07.052>. Acesso em: 13 mar. 2020.

NIRUDH, J.; SOMCHAT, J. Estimation of Solar Potential for Thailand Using Adaptive Neurofuzzy Inference System Models. **Journal of Solar Energy Engineering**, Vol. 141 / 061009-1, 2019. Disponível em: <http://dx.doi.org/10.1115/1.4043826>. Acesso em: 10 jan. 2020.

NOBRE, A.M. *et al.* On the impact of haze on the yield of photovoltaic systems in Singapore. **Renewable Energy**, 89:389-400, 2016. Disponível em: <http://dx.doi.org/10.1016/j.renene.2015.11.079>. Acesso em: 02 nov. 2021.

NONNENMACHER, L.; KAUR, A.; COIMBRA, C.F.M. Day-ahead resource forecasting for concentrated solar power integration. **Renewable Energy**, 86:866-876, 2016. Disponível em: <http://dx.doi.org/10.1016/j.renene.2015.08.068>. Acesso em: 20 abr. 2021.

NUÑO, E. *et al.* On the Simulation of Aggregated Solar PV Forecast Errors. **IEEE Transactions on Sustainable Energy**, Vol. 9, No. 4, 2018. Disponível em: <https://doi.org/10.1109/TSTE.2018.2818727>. Acesso em: 20 ago. 2020.

NUÑO, E. *et al.* Simulation of regional day-ahead PV power forecast Scenarios. **IEEE Manchester PowerTech**, 1-6, 2017. Disponível em: <https://doi.org/10.1109/PTC.2017.7981155>. Acesso em: 13 abr. 2021.

NGUYEN, N. T. A.; LE, D. D. Day-ahead Coordinated Operation of a Wind-Storage System Considering Wind Forecast Uncertainty. **Engineering, Technology & Applied Science Research**, 11(3), 7201-7206, 2021. Disponível em: <https://www.etasr.com/index.php/ETASR/article/view/4176>. Acesso em: 12 fev. 2023.

ORTIZ, J. R. A. **El Potencial Eólico em Espanha, Estudo Técnico PER 2011-2020**. Instituto para la Diversificación y Ahorro de la Energía (IDAE), 2011.

OZOEGBU, C.G. Artificial neural network forecast of monthly mean daily global solar radiation of selected locations based on time series and month number. **Journal of Cleaner Production**, 216:1-13, 2019. Disponível em: <https://doi.org/10.1016/j.jclepro.2019.01.096>. Acesso em: 15 jun. 2020.

PAULESCU, M. *et al.* Structured, physically inspired (gray box) models versus black box modeling for forecasting the output power of photovoltaic plants. **Energy**, 121:792-802, 2017. Disponível em: <http://dx.doi.org/10.1016/j.energy.2017.01.015>. Acesso em: 10 abr. 2021.

PEDRO, H. T. C. *et al.* Assessment of machine learning techniques for deterministic and probabilistic intra-hour solar forecasts. **Renewable Energy**, 123:191-203, 2018b. Disponível em: <https://doi.org/10.1016/j.renene.2018.02.006>. Acesso em: 04 jul. 2021.

PEDRO, H.T.C.; COIMBRA, C.F.M. Nearest-neighbor methodology for prediction of intra-hour global horizontal and direct normal irradiances. **Renewable Energy**, 80:770-782, 2015a. Disponível em: <http://dx.doi.org/10.1016/j.renene.2015.02.061>. Acesso em: 02 ago. 2021.

PEDRO, H.T.C.; LIM, E.; COIMBRA, C.F.M. A database infrastructure to implement real-

time solar and wind power generation intra-hour forecasts. **Renewable Energy**, 123:513-525, 2018a. Disponível em: <https://doi.org/10.1016/j.renene.2018.02.043>. Acesso em: 12 ago. 2021.

PEDRO, H.T.C.; COIMBRA, C.F.M. Short-term irradiance forecastability for various solar micro-climates. **Solar Energy**, 122:587–602, 2015. Disponível em: <http://dx.doi.org/10.1016/j.solener.2015.09.031>. Acesso em: 22 ago. 2020.

PENG, L. H. *et al.* A computational study of potential miRNA-disease association inference based on ensemble learning and kernel ridge regression. **Frontiers in bioengineering and biotechnology**, 8, 40, 2020. Disponível em: <https://doi.org/10.3389/fbioe.2020.00040>. Acesso em: 12 out. 2021.

PEREIRA, E. B. *et al.* **Atlas brasileiro de energia solar**. São José dos Campos: Inpe, 1, 2017.

PEREPU, S. K. *et al.* Reinforcement Learning based dynamic weighing of Ensemble Models for Time Series Forecasting. **arXiv preprint arXiv**, 2008.08878, 2020. Disponível em: <https://arxiv.org/abs/2008.08878>. Acesso em: 03 abr. 2021.

PERUCHENA, C.M.F. *et al.* Dynamic Paths: Towards high frequency direct normal irradiance forecasts. **Energy**, 132: 315-323, 2017. Disponível em: <http://dx.doi.org/10.1016/j.energy.2017.05.101>. Acesso em: 20 mai. 2021.

PIERRO, M. *et al.* Deterministic and Stochastic Approaches for Day-Ahead Solar Power Forecasting. **Journal of Solar Energy Engineering**, Vol. 139/021010-1, 2017. Disponível em: <http://dx.doi.org/10.1115/1.4034823>. Acesso em: 13 mai. 2021.

PINHEIRO, V. C. N. **Despacho Ótimo De Sistemas Elétricos Com Armazenamento De Energia Para Fontes Intermitentes De Geração No Brasil**. 2020. Tese (Doutorado em Engenharia Civil). Universidade Estadual de Campinas, Faculdade de Engenharia Civil, Arquitetura e Urbanismo, Campinas, 2020. Disponível em: [https://www.researchgate.net/publication/347439134\\_DESPACHO\\_OTIMO\\_DE\\_SISTEMAS\\_ELETRICOS\\_COM\\_ARMAZENAMENTO\\_DE\\_ENERGIA\\_PARA\\_FONTES\\_INTERMITENTES\\_DE\\_GERACAO\\_NO\\_BRASIL](https://www.researchgate.net/publication/347439134_DESPACHO_OTIMO_DE_SISTEMAS_ELETRICOS_COM_ARMAZENAMENTO_DE_ENERGIA_PARA_FONTES_INTERMITENTES_DE_GERACAO_NO_BRASIL). Acesso em: 15 jun. 2020.

PONCELA-BLANCO, M.; PONCELA, P. Improving Wind Power Forecasts: Combination through Multivariate Dimension Reduction Techniques. **Energies**, 14(5), 1446, 2021. Disponível em: <https://doi.org/10.3390/en14051446>. Acesso em: 12 dez. 2021.

PRADO-RUJAS, I. *et al.* A Flexible and Robust Deep Learning-Based System for Solar Irradiance Forecasting. **IEEE Access**, Vol. 9, 2021. Disponível em: <http://dx.doi.org/10.1109/access.2021.3051839>. Acesso em: 11 jan. 2022.

PRASAD, R. *et al.* Designing a multi-stage multivariate empirical mode decomposition coupled with ant colony optimization and random forest model to forecast monthly solar radiation. **Applied Energy**, 236:778–792, 2019. Disponível em: <https://doi.org/10.1016/j.apenergy.2018.12.034>. Acesso em: 10 jun. 2020.

PRASAD, R. *et al.* A double decomposition-based modelling approach to forecast weekly solar radiation. **Renewable Energy**, 152:9-22, 2020. Disponível em:



<https://doi.org/10.1016/j.renene.2020.01.005>. Acesso em: 11 jun. 2021.

PAULA, M. *et al.* Predicting long-term wind speed in wind farms of northeast brazil: A comparative analysis through machine learning models. **IEEE Latin America Transactions**, 18(11), 2011-2018, 2020. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9398643>. Acesso em: 28 nov. 2022.

PEREYRA-CASTRO, K.; CAETANO, E.; ALTAMIRANO DEL RAZO, D. WRF wind forecast over coastal complex terrain: Baja California Peninsula (Mexico) case study. **Arabian Journal of Geosciences**, 14(19), 1972, 2021. Disponível em: <https://link.springer.com/article/10.1007/s12517-021-08317-3>. Acesso em: 20 nov. 2022.

PIERRO, M. *et al.* Impact of PV/Wind Forecast Accuracy and National Transmission Grid Reinforcement on the Italian Electric System. **Energies**, 15(23), 9086, 2022. Disponível em: <https://www.mdpi.com/1996-1073/15/23/9086>. Acesso em: 13 abr. 2023.

PREMA, V. *et al.* Critical review of data, models and performance metrics for wind and solar power forecast. **IEEE Access**, 10, 667-688, 2021. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9658498>. Acesso em: 20 fev. 2023.

PUJARI, K.N. *et al.* Better wind forecasting using Evolutionary Neural Architecture search driven Green Deep Learning. **Expert Systems with Applications**, 214, 119063, 2023. Disponível em: <https://doi.org/10.1016/j.eswa.2022.119063>. Acesso em 24 mai. 2023.

QING, X.; NIU, Y. Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM. **Energy**, 148:461–8, 2018. Disponível em: <https://doi.org/10.1016/j.energy.2018.01.177>. Acesso em: 08 mai. 2020.

RAFFÁN, L.C.P.; ROMERO, A.; MARTINEZ, M. Solar energy production forecasting through artificial neuronal networks, considering the Föhn, north and south winds in San Juan, Argentina. **The 7th International Conference on Renewable Power Generation**, 2018. Disponível em: <https://doi.org/10.1049/joe.2018.9368>. Acesso em: 20 mai. 2020.

RAGHAVAN, V. S. G.; GOPALAN, H. URB-Solar: An Open-Source Tool for Solar Power Prediction in Urban Areas. **Journal of Solar Energy Engineering**, Vol. 140/064501-1, 2018. Disponível em: <http://dx.doi.org/10.1115/1.4040756>. Acesso em: 02 abr. 2020.

RAHMANN, C.; MAYOL, C.; HAAS, J. Dynamic control strategy in partially-shaded photovoltaic power plants for improving the frequency of the electricity system. **Journal of Cleaner Production**, 202:109-119, 2018. Disponível em: <https://doi.org/10.1016/j.jclepro.2018.07.310>. Acesso em: 23 jun. 2021.

RAZA, M. Q.; NADARAJAH, M.; EKANAYAKE, C. Demand forecast of PV integrated bioclimatic buildings using ensemble framework. **Applied Energy**, 208, 1626-1638, 2017. Disponível em: <https://doi.org/10.1016/j.apenergy.2017.08.192>. Acesso em: 12 abr. 2021.

**Reddata da Red Electrica de Españã**. Disponível em: <https://www.ree.es/es/datos/generacion>. Acesso em: 15 fev. 2022.

REIKARD, G.; HANSEN, C. Forecasting solar irradiance at short horizons: Frequency and

- time domain models. **Renewable Energy**, 135:1270-1290, 2019. Disponível em: <https://doi.org/10.1016/j.renene.2018.08.081>. Acesso em: 10 jun. 2020.
- REIKARD, G.; HAUPT, S.E.; JENSEN, T. Forecasting ground-level irradiance over short horizons: Time series, meteorological, and time-varying parameter models. **Renewable Energy**, 112:474-485, 2017. Disponível em: <http://dx.doi.org/10.1016/j.renene.2017.05.019>. Acesso em: 10 abr. 2020.
- RENNER, M.C. **‘Markowitz portfolio theory at times of crisis’**. Specialization in Capital Markets, Federal University of Rio Grande do Sul, Porto Alegre, 2010.
- RISSE, M. Combining wavelet decomposition with machine learning to forecast gold returns. **International Journal of Forecasting**, 35(2), 601-615, 2019. Disponível em: <https://doi.org/10.1016/j.ijforecast.2018.11.008>. Acesso em: 10 fev. 2020.
- ROCHA, P. C. *et al.* Estimation of daily, weekly and monthly global solar radiation using ANNs and a long data set: a case study of Fortaleza, in Brazilian Northeast region. **International Journal of Energy and Environmental Engineering**, 10, 319-334, 2019. Disponível em: <https://doi.org/10.1007/s40095-019-0313-0>. Acesso em: 02 jun. 2021.
- ROKACH, L. **Ensemble Learning: Pattern Classification Using Ensemble Methods**; World Scientific Publishing CoPte Ltd.: Singapore, 2019.
- SAHU, D.K.; YANG, H.; KLEISSL, J. Assimilating observations to simulate marine layer stratocumulus for solar forecasting. **Solar Energy**, 162:454–471, 2018. Disponível em: <https://doi.org/10.1016/j.solener.2018.01.006>. Acesso em: 06 fev. 2020.
- SALLÉ ALONSO, C. **“El déficit de tarifa y la importancia de la ortodoxia en la regulación del sector eléctrico”**. Papeles de Economía Española, nº 134, 2012.
- SANTOS, I. S. *et al.* Test case design for context-aware applications: Are we there yet?. **Information and Software Technology**, 88: 1–16, 2017. Disponível em: <http://dx.doi.org/10.1016/j.infsof.2017.03.008>. Acesso em: 15 abr. 2020.
- SARAIVA, S. V. *et al.* Prognóstico de Radiação Solar Através Modelos que combinam as Técnicas Wavelet e Redes Neurais. **Revista Brasileira de Geografia Física**, 7(5), 808-817, 2014. Disponível em: <https://periodicos.ufpe.br/revistas/rbgfe/article/viewFile/233342/27114>. Acesso em: 13 mai. 2020.
- SCHMELAS, M. *et al.* Photovoltaics Energy Prediction Under Complex Conditions for a Predictive Energy Management System. **Journal of Solar Energy Engineering**, Vol. 137 / 031015-1, 2015. Disponível em: <http://dx.doi.org/10.1115/1.4029378>. Acesso em: 05 abr. 2020.
- SERRANO-GUERRERO, X. *et al.* A new interval prediction methodology for short-term electric load forecasting based on pattern recognition. **Applied Energy**, 297, 117173, 2021. Disponível em: <https://doi.org/10.1016/j.apenergy.2021.117173>. Acesso em: 10 jan. 2022.
- SHIREEN, T. *et al.* Iterative multi-task learning for time-series modeling of solar panel PV outputs. **Applied Energy**, 212:654–662, 2018. Disponível em:

<https://doi.org/10.1016/j.apenergy.2017.12.058>. Acesso em: 15 jul. 2020.

SIDERATOS, G.; HATZIARGYRIOU, N. D. A distributed memory RBF-based model for variable generation forecasting. **International Journal of Electrical Power & Energy Systems**, 120, 106041, 2020. Disponível em: <https://doi.org/10.1016/j.ijepes.2020.106041>. Acesso em: 15 jun. 2021.

SIDERATOS, G.; HATZIARGYRIOU, N.D. An Advanced Statistical Method for Wind Power Forecasting, **IEEE Transactions on Power Systems** 2007; 22(1), 258-265.

SILVA, A. W. B. *et al.* Methodology Based on Artificial Neural Networks for Hourly Forecasting of PV Plants Generation. **IEEE Latin America Transactions**, 20(4), 659-668, 2022. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9675472>. Acesso em: 10 dez. 2022.

SONG, Y. *et al.* Short-term load forecasting in electrical power systems via trajectory tracking and error correcting approach. **J. Renewable Sustainable Energy**. 6, 013112, 2014; Disponível em: <https://doi.org/10.1063/1.4861784>. Acesso em: 15 abr. 2020.

SOUMYASHREE, K. *et al.* An ensemble machine learning approach for determination of the optimum sampling time for evapotranspiration assessment from high-throughput phenotyping data. **Computers and Electronics in Agriculture**, V. 182, 105992, 2021, ISSN 0168-1699. Disponível em: <https://doi.org/10.1016/j.compag.2021.105992>. Acesso em: 08 dez. 2021.

SPERATI, S. *et al.* The “weather intelligence for renewable energies” benchmarking exercise on short-term forecasting of wind and solar power generation, **Energies**, 8: 9594–9619, 2015. Disponível em: <https://www.mdpi.com/1996-1073/8/9/9594>. Acesso em: 15 abr. 2020.

SPETH, V. Wind and solar portfolios and their impact on predictability: German case study 2010-2011. In: **11TH International Workshop on large-scale integration of wind power into power systems as well as on transmission networks for offshore wind power plants**. 11., 2012, Lisbon. Anais [...] Lisbon: energynautics, 2012. 1-6p. Disponível em: <https://windintegrationworkshop.org/lisbon2012/index.html>. Acesso em 10 set. 2018.

SRIDHARAN, M. *et al.* Prediction of Solar Photovoltaic/Thermal Collector Power Output Using Fuzzy Logic. **Journal of Solar Energy Engineering**, Vol. 140 / 061013-1, 2018. Disponível em: <http://dx.doi.org/10.1115/1.4040757>. Acesso em: 20 jun. 2021.

STEFENON, S. F. *et al.* Time series forecasting using ensemble learning methods for emergency prevention in hydroelectric power plants with dam. **Electric Power Systems Research**, 202, 107584, 2022. Disponível em: <https://doi.org/10.1016/j.epsr.2021.107584>. Acesso em: 03 dez. 2022.

SUNIL, S. *et al.* Hybrid ensemble machine learning approaches for landslide susceptibility mapping using different sampling ratios at East Sikkim Himalayan, India. **Advances in Space Research**, ISSN 0273-1177, 2021. Disponível em: <https://doi.org/10.1016/j.asr.2021.05.018>. Acesso em: 15 fev. 2022.

SURESH, V. *et al.* Forecasting Solar PV Output Using Convolutional Neural Networks with a Sliding Window Algorithm. **Energies**, 13:723, 2020. Disponível em:

<https://doi.org/10.3390/en13030723>. Acesso em: 1 mai. 2021.

SANJARI, M.J.; GOOI, H.B.; NAIR, N.K.C. Power generation forecast of hybrid PV–wind system. **IEEE Transactions on Sustainable Energy**, 11(2), 703-712, 2019. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8663334>. Acesso em: 14 abr. 2023.

SANTOS, V. O. *et al.* Spatiotemporal analysis of bidimensional wind speed forecasting: Development and thorough assessment of LSTM and ensemble graph neural networks on the Dutch database. **Energy**, 127852, 2023. Disponível em: <https://doi.org/10.1016/j.energy.2023.127852>. Acesso em: 06 jun. 2023.

SHAHID, F.; ZAMEER, A.; MUNEEB, M. A novel genetic LSTM model for wind power forecast. **Energy**, 223, 120069, 2021. Disponível em: <https://doi.org/10.1016/j.energy.2021.120069>. Acesso em: 15 abr. 2022.

SHIN, J. Y.; MIN, B.; KIM, K. R. High-resolution wind speed forecast system coupling numerical weather prediction and machine learning for agricultural studies—a case study from South Korea. **International Journal of Biometeorology**, 66(7), 1429-1443, 2022. Disponível em: <https://link.springer.com/article/10.1007/s00484-022-02287-1>. Acesso em: 14 mai. 2022.

SINGH, S. N., MOHAPATRA, A. Repeated wavelet transform based ARIMA model for very short-term wind speed forecasting. **Renewable energy**, 136, 758-768, 2019. Disponível em: <https://doi.org/10.1016/j.renene.2019.01.031>. Acesso em: 15 ago. 2022.

SUN, W. *et al.* Improving wind speed forecasts at wind turbine locations over Northern China through assimilating nacelle winds with WRFDA. **Weather and Forecasting**, 37(5), 545-562, 2022. Disponível em: <https://iopscience.iop.org/article/10.1088/1742-6596/1618/6/062034/meta>. Acesso em: 20 abr. 2023.

SUN, Z.; ZHAO, M. Short-term wind power forecasting based on VMD decomposition, ConvLSTM networks and error analysis. **IEEE Access**, 8, 134422-134434, 2020. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9146109>. Acesso em: 10 out. 2022.

TAYLOR, J.W. Forecast combinations for value at risk and expected shortfall. **International Journal of Forecasting**, 36(2), 428–441, 2020. Disponível em: <https://doi.org/10.1016/j.ijforecast.2019.05.014>. Acesso em: 20 out. 2021.

TAZIM, A. *et al.* Warpaga prediction of Injection-molded PVC part using ensemble machine learning algorithm. **Materials Today: Proceedings**, ISSN 2214-7853, 2020. Disponível em: <https://doi.org/10.1016/j.matpr.2020.11.463>. Acesso em: 13 jun. 2021.

TEIXEIRA JÚNIOR, L. A. *et al.* Redes Neurais Artificiais e Decomposição Wavelet na Previsão da Radiação Solar Direta. **Simpósio Brasileiro de Pesquisa Operacional**, Rio de Janeiro, 2012. Disponível em: <http://ws2.din.uem.br/~ademir/sbpo/sbpo2012/pdf/arq0282.pdf>. Acesso em 15 out. 2020.

TIBSHIRANI, R. Regression shrinkage and selection via the lasso. **Journal of the Royal Statistical Society: Series B (Methodological)**, 58(1), 267-288, 1996. Disponível em: <https://doi.org/10.1111/j.2517-6161.1996.tb02080.x>, Acesso em: 14 abr. 2020.

TRAPERO, J.R. Calculation of solar irradiation prediction intervals combining volatility and kernel density estimates. **Energy**, 114:266-274, 2016. Disponível em: <http://dx.doi.org/10.1016/j.energy.2016.07.167>. Acesso em: 05 ago. 2021.

UZINSKI, J. C.; DE OLIVEIRA, B. R.; DE ABREU, C. C. E. **Obtenção de Tendências em Série Temporal empregando a Transformada Wavelet e o filtro Savitzky-Golay**. In Aplicações de Inteligência Artificial e Ciência de Dados, Capítulo 1, Nova Xavantia: Pantnal, 2020.

VAN DER MEER, D.W. *et al.* Probabilistic forecasting of electricity consumption, photovoltaic power generation and net demand of an individual building using Gaussian Processes. **Applied Energy**, 213:195–207, 2018. Disponível em: <https://doi.org/10.1016/j.apenergy.2017.12.104>. Acesso em: 20 abr. 2021.

VAZ, A.G.R. *et al.* An artificial neural network to assess the impact of neighboring photovoltaic systems in power forecasting in Utrecht, the Netherlands. **Renewable Energy**, 85:631-641, 2016. Disponível em: <http://dx.doi.org/10.1016/j.renene.2015.06.061>. Acesso em: 15 ago. 2021.

VERBOIS, H. *et al.* Solar irradiance forecasting in the tropics using numerical weather prediction and statistical learning. **Solar Energy**, 162:265–277, 2018. Disponível em: <https://doi.org/10.1016/j.solener.2018.01.007>. Acesso em: 12 mai. 2021.

VOYANT, C. *et al.* Forecasting method for global radiation time series without training phase: Comparison with other well-known prediction methodologies. **Energy**, 120:199-208, 2017a. Disponível em: <http://dx.doi.org/10.1016/j.energy.2016.12.118>. Acesso em: 04 ago. 2020.

VOYANT, C. *et al.* Uncertainties in global radiation time series forecasting using machine learning: The multilayer perceptron case. **Energy**, 125:248-257, 2017b. Disponível em: <http://dx.doi.org/10.1016/j.energy.2017.02.098>. Acesso em: 15 mai. 2021.

WANG, G.C. *et al.* Corrective receding horizon EV charge scheduling using short-term solar forecasting. **Renewable Energy**, 130:1146-1158, 2019c. Disponível em: <https://doi.org/10.1016/j.renene.2018.08.056>. Acesso em: 20 mar. 2020.

WANG, G.C.; URQUHART, B.; KLEISSL, J. Cloud base height estimates from sky imagery and a network of pyranometers. **Solar Energy**, 184:594–609, 2019d. Disponível em: <https://doi.org/10.1016/j.solener.2019.03.101>. Acesso em: 10 abr. 2021.

WANG, K.; QI, X.; LIU, H. A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network. **Applied Energy**, 251: 113315, 2019a. Disponível em: <https://doi.org/10.1016/j.apenergy.2019.113315>. Acesso em: 14 ago. 2020.

WANG, K.; QI, X.; LIU H. Photovoltaic power forecasting-based LSTM-Convolutional Network. **Energy**, 189:116225, 2019b. Disponível em: <https://doi.org/10.1016/j.energy.2019.116225>. Acesso em: 20 mai. 2020.

WANG, Y.; WU L. On practical challenges of decomposition-based hybrid forecasting algorithms for wind speed and solar irradiation. **Energy**, 112:208-220, 2016. Disponível em:

<http://dx.doi.org/10.1016/j.energy.2016.06.075>. Acesso em: 13 ago. 2020.

WANG, X. *et al.* Estimates of energy consumption in China using a self-adaptive multi-verse optimizer-based support vector machine with rolling cross-validation. **Energy**, 152, 539-548, 2018. Disponível em: <https://doi.org/10.1016/j.energy.2018.03.120>. Acesso em: 15 mai. 2021.

WANG, Z.; GUO, Z. On critical timescale of real-time power balancing in power systems with intermittent power sources. **Electric Power Systems Research**, 155, 246-253, 2018. Disponível em: <https://doi.org/10.1016/j.epsr.2017.10.022>. Acesso em: 05 abr. 2020.

WEI, S. *et al.* Motor-generator pair: a novel solution to provide inertia and damping for power system with high penetration of renewable energy, **IET Generation, Transmission & Distribution**, 11(7), 1839-1847, 2017. Disponível em: <https://doi.org/10.1049/iet-gtd.2016.1894>. Acesso em: 13 ago. 2020.

WEN, H. *et al.* Deep Learning Based Multistep Solar Forecasting for PV Ramp-Rate Control Using Sky Images. **IEEE Transactions on Industrial Informatics**, Vol. 17, No. 2, 2021. Disponível em: <http://dx.doi.org/10.1109/TII.2020.2987916>. Acesso em: 09 dez. 2022.

WERNER, L.; RIBEIRO, J. L. D. Modelo composto para prever demanda através da integração de previsões. **Production** 2006, 16, 493-509. Disponível em: <https://www.scielo.br/j/prod/a/mQHMsVRLXWnJGxLS3NXFcrJ/abstract/?lang=pt>. Acesso em: 17 abr. 2021.

WOLFF, B. *et al.* Comparing support vector regression for PV power forecasting to a physical modeling approach using measurement, numerical weather prediction, and cloud motion data. **Solar Energy**, 135:197–208, 2016. Disponível em: <http://dx.doi.org/10.1016/j.solener.2016.05.051>. Acesso em 20 mai. 2021.

WOLPERT, D.; MACREADY, W. No free lunch theorems for optimization, **IEEE Transactions on Evolutionary Computation**, 1(1):67-82, 1997. Disponível em: <http://dx.doi.org/10.1109/4235.585893>. Acesso em: 25 ago. 2020.

WORSNOP, R. P.; SCHEUERER, M.; HAMILL, T. M. Extended-range probabilistic fire-weather forecasting based on ensemble model output statistics and ensemble copula coupling. **Monthly Weather Review**, 148(2), 499-521, 2020. Disponível em: <https://doi.org/10.1175/MWR-D-19-0217.s1>. Acesso em: 04 jun. 2021.

WU, E.; CLEMESHA, R.E.S.; KLEISSL, J. Coastal Stratocumulus cloud edge forecasts. **Solar Energy**, 164:355–369, 2018. Disponível em: <https://doi.org/10.1016/j.solener.2018.02.072>. Acesso em: 11 jan. 2020.

WU, J.; CHAN, C.K. **The prediction of monthly average solar radiation with TDNN and ARIMA, in machine learning and applications (ICMLA)**, pp. 469–74, 2012.

WANG, C. *et al.* Wind speed forecasting based on hybrid model with model selection and wind energy conversion. **Renewable Energy**, 196, 763-781, 2022. Disponível em: <https://doi.org/10.1016/j.renene.2022.06.143>. Acesso em: 13 abr. 2023.

- WANG, K. *et al.* Nonparametric Probabilistic Forecasting for Wind Power Generation Using Quadratic Spline Quantile Function and Autoregressive Recurrent Neural Network. **IEEE Transactions on Sustainable Energy**, 13(4), 1930-1943, 2022a. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9779444>. Acesso em: 25 ago. 2022.
- WANG, L.; LI, X.; BAI, Y. Short-term wind speed prediction using an extreme learning machine model with error correction. **Energy Conversion and Management**, 162, 239-250, 2018. Disponível em: <https://doi.org/10.1016/j.enconman.2018.02.015>. Acesso em: 20 mai. 2023.
- WANG, Y. *et al.* A convolutional Transformer-based truncated Gaussian density network with data denoising for wind speed forecasting. **Applied Energy**, 333, 120601, 2023. Disponível em: <https://doi.org/10.1016/j.apenergy.2022.120601>. Acesso em: 24 mai. 2023.
- WANG, Y. *et al.* A review of wind speed and wind power forecasting with deep neural networks. **Applied Energy**, 304, 117766, 2021. Disponível em: <https://doi.org/10.1016/j.apenergy.2021.117766>. Acesso em: 12 fev. 2023.
- WANG, Z. *et al.* Short-term wind speed forecasting based on information of neighboring wind farms. **IEEE Access**, 8, 16760-16770, 2020. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8957478>. Acesso em: 13 ago. 2022.
- WEN, H. *et al.* Wind energy forecasting with missing values within a fully conditional specification framework. **International Journal of Forecasting**, 2023. Disponível em: <https://doi.org/10.1016/j.ijforecast.2022.12.006>. Acesso em: 06 jun. 2023.
- WILCZAK, J.M. *et al.* Data assimilation impact of in situ and remote sensing meteorological observations on wind power forecasts during the first Wind Forecast Improvement Project (WFIP). **Wind Energy**, 22: 932– 944, 2019. Disponível em: <https://doi.org.ez11.periodicos.capes.gov.br/10.1002/we.2332>. Acesso em: 08 jan. 2023.
- WU, Y. X.; WU, Q. B.; ZHU, J. Q. Data-driven wind speed forecasting using deep feature extraction and LSTM. **IET Renewable Power Generation**, 13(12), 2062-2069, 2019. Disponível em: <https://doi.org/10.1049/iet-rpg.2018.5917>. Acesso em: 05 jul. 2022.
- WU, Y.K. *et al.* Deterministic and Probabilistic Wind Power Forecasts by Considering Various Atmospheric Models and Feature Engineering Approaches. **IEEE Transactions on Industry Applications**, 2022. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9928779>. Acesso em: 24 mai. 2023.
- WU, Y.K. *et al.* Probabilistic wind-power forecasting using weather ensemble models. **IEEE Transactions on Industry Applications**, 54(6), 5609-5620, 2018a. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8416742>. Acesso em: 15 dez. 2022.
- XIANG, L.; DENG, Z.; HU, A. Forecasting short-term wind speed based on IEWT-LSSVM model optimized by bird swarm algorithm. **IEEE Access**, 7, 59333-59345, 2019. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8703830>. Acesso em: 20 jul. 2022.

- YAN, J. *et al.* Hybrid probabilistic wind power forecasting using temporally local gaussian process. **IEEE Transactions on sustainable energy**, 7(1), 87-95, 2016. Disponível em: <https://ieeexplore.ieee.org/abstract/document/7274766>. Acesso em: 18 out. 2020.
- YANG, D. A universal benchmarking method for probabilistic solar irradiance forecasting. **Solar Energy**, 184:410–416, 2019b. Disponível em: <https://doi.org/10.1016/j.solener.2019.04.018>. Acesso em: 20 out. 2021.
- YANG, D. Ensemble model output statistics as a probabilistic site-adaptation tool for satellite derived and reanalysis solar irradiance. **Renewable Sustainable Energy**, 12:016102, 2020. Disponível em: <https://doi.org/10.1063/1.5134731>. Acesso em: 23 fev. 2021.
- YANG, D. On post-processing day-ahead NWP forecasts using Kalman filtering. **Solar Energy**, 182:179–181, 2019a. Disponível em: <https://doi.org/10.1016/j.solener.2019.02.044>. Acesso em: 23 fev. 2021.
- YANG, D. SolarData: An R package for easy access of publicly available solar datasets. **Solar Energy**, 171:A3–A12, 2018. Disponível em: <https://doi.org/10.1016/j.solener.2018.06.107>. Acesso em: 10 fev. 2021.
- YANG, D. Standard of reference in operational day-ahead deterministic solar forecasting. **Renewable Sustainable Energy**, 11:053702, 2019c. Disponível em: <https://doi.org/10.1063/1.5114985>. Acesso em: 18 abr. 2020.
- YANG, D.; DONG, Z. Operational photovoltaics power forecasting using seasonal time series ensemble. **Solar Energy**, 166:529–541, 2018. Disponível em: <https://doi.org/10.1016/j.solener.2018.02.011>. Acesso em: 10 abr. 2020.
- YANG, D.; GUEYMARD, C.A. Producing high-quality solar resource maps by integrating high- and low accuracy measurements using Gaussian processes. **Renewable and Sustainable Energy Reviews**, 113: 109260, 2019. Disponível em: <https://doi.org/10.1016/j.rser.2019.109260>. Acesso em: 05 out. 2020.
- YANG, D. *et al.* Forecasting of global horizontal irradiance by exponential smoothing, using decompositions. **Energy** 81:111-119, 2015. Disponível em: <http://dx.doi.org/10.1016/j.ene,rgy.2014.11.082>. Acesso em:
- YANG, D.; WU, E.; KLEISSL, J. Operational solar forecasting for the real-time market. **International Journal of Forecasting**, 35:1499–1519, 2019. Disponível em: <https://doi.org/10.1016/j.ijforecast.2019.03.009>. Acesso em: 15 jul. 2021.
- YANG, D. *et al.* Very short-term irradiance forecasting using the lasso. **Solar Energy**, 114: 314–326, 2015a. Disponível em: <http://dx.doi.org/10.1016/j.solener.2015.01.016>. Acesso em: 20 jun. 2020.
- YANG, H.; KLEISSL, J. Preprocessing WRF initial conditions for coastal stratocumulus forecasting. **Solar Energy**, 133:180–193, 2016. Disponível em: <http://dx.doi.org/10.1016/j.solener.2016.04.003>. Acesso em: 11 mai. 2021.
- YANG, D. Making reference solar forecasts with climatology, persistence, and their optimal



convex combination. **Solar Energy**, 193:981–985, 2019. Disponível em: <https://doi.org/10.1016/j.solener.2019.10.006>. Acesso em: 20 ago. 2021.

YANG, D.; WALSH, W.M.; JIRUTITIJAROEN P. Estimation and applications of clear sky global horizontal irradiance at the equator. **Journal of Solar Energy Engineering**, 136(3), 2014. Disponível em: <https://doi.org/10.1115/1.4027263>. Acesso em: 22 mai. 2020.

YANG, Y.; YANG, Y. Hybrid prediction method for wind speed combining ensemble empirical mode decomposition and bayesian ridge regression. **IEEE Access**, 8, 71206-71218, 2020. Disponível em: <https://doi.org/10.1109/ACCESS.2020.2984020>. Acesso em: 10 abr. 2021.

YAGHOUBIRAD, M. *et al.* Deep learning-based multistep ahead wind speed and power generation forecasting using direct method. **Energy Conversion and Management**, 281, 116760, 2023. Disponível em: <https://doi.org/10.1016/j.enconman.2023.116760>. Acesso em: 15 abr. 2023.

YAKOUB, G.; MATHEW, S.; LEAL, J. Downscaling and improving the wind forecasts from NWP for wind energy applications using support vector regression. **Journal of Physics: Conference Series** (Vol. 1618, No. 6, p. 062034). IOP Publishing, 2020. Disponível em: <https://iopscience.iop.org/article/10.1088/1742-6596/1618/6/062034/meta>. Acesso em: 04 abr. 2023.

YAN, J. *et al.* Forecasting the high penetration of wind power on multiple scales using multi-to-multi mapping. **IEEE Transactions on Power Systems**, 33(3), 3276-3284, 2018. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8240639>. Acesso em: 20 jun. 2022.

YANG, W.; HAO, M.; HAO, Y. Innovative ensemble system based on mixed frequency modeling for wind speed point and interval forecasting. **Information Sciences**, 622, 560-586, 2023.

YILDIZ, C. *et al.* An improved residual-based convolutional neural network for very short-term wind power forecasting. **Energy Conversion and Management**, 228, 113731, 2021. Disponível em: <https://doi.org/10.1016/j.enconman.2020.113731>. Acesso em: 23 nov. 2022.

YOUSUF, M.U.; AL-BAHADLY, I.; AVCI, E. Current perspective on the accuracy of deterministic wind speed and power forecasting. **IEEE Access**, 7, 159547-159564, 2019. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8890707>. Acesso em: 12 mar. 2023.

YOUSUF, M.U.; AL-BAHADLY, I.; AVCI, E. Short-term wind speed forecasting based on hybrid MODWT-ARIMA-Markov model. **IEEE Access**, 9, 79695-79711, 2021. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9442729>. Acesso em: 29 fev. 2023.

YU, C. *et al.* A novel framework for wind speed prediction based on recurrent neural networks and support vector machine. **Energy Conversion and Management**, 178, 137-145, 2018. Disponível em: <https://doi.org/10.1016/j.enconman.2018.10.008>. Acesso em: 18 jun. 2023.

ZAMO, M.; BEL, L.; MESTRE, O. Sequential aggregation of probabilistic forecasts—application to wind speed ensemble forecasts. **Journal of the Royal Statistical Society Series C: Applied Statistics**, 70(1), 202-225, 2021. Disponível em: <https://doi.org/10.1111/rssc.12455>. Acesso em: 23 jan. 2023.

ZHANG, D. *et al.* A novel wind speed forecasting based on hybrid decomposition and online sequential outlier robust extreme learning machine. **Energy conversion and management**, 180, 338-357, 2019. Disponível em: <https://doi.org/10.1016/j.enconman.2018.10.089>. Acesso em: 14 jun. 2023.

ZHANG, L.; DONG, Y.; WANG, J. Wind speed forecasting using a two-stage forecasting system with an error correcting and nonlinear ensemble strategy. **IEEE Access**, 7, 176000-176023, 2019. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8918398>. Acesso em: 20 jun. 2022.

ZHANG, L. *et al.* A multistep wind speed forecasting system considering double time series features. **IEEE Access**, 8, 161018-161030, 2020. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9184891>. Acesso em: 25 jun. 2022.

ZHANG, S. *et al.* Research on combined model based on multi-objective optimization and application in wind speed forecast. **Applied Sciences**, 9(3), 423, 2019. Disponível em: <https://www.mdpi.com/2076-3417/9/3/423>. Acesso em: 20 fev. 2023.

ZHANG, W. *et al.* A deep learning method for real-time bias correction of wind field forecasts in the Western North Pacific. **Atmospheric Research**, 284, 106586, 2023. Disponível em: <https://doi.org/10.1016/j.atmosres.2022.106586>. Acesso em: 23 mai. 2023.

ZHANG, Z. *et al.* A novel ensemble system for short-term wind speed forecasting based on Two-stage Attention-Based Recurrent Neural Network. **Renewable Energy**, 2023a. Disponível em: <https://doi.org/10.1016/j.renene.2022.12.120>. Acesso em: 24 mai. 2023.

ZHAO, Z. *et al.* Hybrid VMD-CNN-GRU-based model for short-term forecasting of wind power considering spatio-temporal features. **Engineering Applications of Artificial Intelligence**, 121, 105982, 2023. Disponível em: <https://doi.org/10.1016/j.engappai.2023.105982>. Acesso em: 20 mai. 2023.

ZHU, J.; SU, L.; LI, Y. Wind power forecasting based on new hybrid model with TCN residual modification. **Energy and AI**, 10, 100199, 2022. Disponível em: <https://doi.org/10.1016/j.egyai.2022.100199>. Acesso em: 20 jan. 2023.

ZAGOURAS, A.; PEDRO, H.T.C; COIMBRA C.F.M. On the role of lagged exogenous variables and spatiotemporal correlations in improving the accuracy of solar forecasting methods. **Renewable Energy**, 78:203-218, 2015. Disponível em: <http://dx.doi.org/10.1016/j.renene.2014.12.071>. Acesso em: 14 fev. 2021.

ZENDEHBOUDI, A.; BASEER, M.A.; SAIDUR, R. Application of support vector machine models for forecasting solar and wind energy resources: A review. **Journal of Cleaner Production**, 199:272e285, 2018. <https://doi.org/10.1016/j.jclepro.2018.07.164>.

ZHANG, C.; MA, Y (Eds.). **Ensemble Machine Learning**. Springer US; 2012. Disponível

em: <https://doi.org/10.1007/978-1-4419-9326-7>. Acesso em: 15 abr. 2020.

ZHAO, C.; GUAN, Y. Data-driven stochastic unit commitment for integrating wind generation. **IEEE Transactions on Power Systems**, 31(4), 2587-2596, 2016. Disponível em: <https://ieeexplore.ieee.org/abstract/document/7283666>. Acesso em: 22 mai. 2020.

ZHAO, W.; WEI, Y. M.; SU, Z. One day ahead wind speed forecasting: A resampling-based approach. **Applied Energy**, 178, 886-901, 2016. Disponível em: <https://doi.org/10.1016/j.apenergy.2016.06.098>. Acesso em: 25 jun. 2023.

ZHENG, J. *et al.* Time series prediction for output of multi-region solar power plants. **Applied Energy**; 257:114001, 2020. Disponível em: <https://doi.org/10.1016/j.apenergy.2019.114001>. Acesso em: 13 ago. 2021.

ZHENG, L. *et al.* Very short-term maximum Lyapunov exponent forecasting tool for distributed photovoltaic output. **Applied Energy**; 229:1128–1139, 2018. Disponível em: <https://doi.org/10.1016/j.apenergy.2018.08.075>. Acesso em: 18 abr. 2021.

ZHOU, Q.; WANG, C.; ZHANG, G. A combined forecasting system based on modified multi-objective optimization and sub-model selection strategy for short-term wind speed. **Applied Soft Computing**, 94, 106463, 2020. Disponível em: <https://doi.org/10.1016/j.asoc.2020.106463>. Acesso em: 12 mai. 2019.

ZHOU, Z.H. **Ensemble Methods: Foundations and Algorithms**; Chapman & Hall/CRC: Boca Raton, FL, USA, 2012.

ZHU, T. *et al.* Clear-sky model for wavelet forecast of direct normal irradiance. **Renewable Energy**, 104:1-8, 2017. Disponível em: <http://dx.doi.org/10.1016/j.renene.2016.11.058>. Acesso em: 30 abr. 2020.

ZJAVKA, L. Photovoltaic power daily predictions using expanding PDE sum models of polynomial networks based on Operational Calculus. **Engineering Applications of Artificial Intelligence**, 89:103409, 2020. Disponível em: <https://doi.org/10.1016/j.engappai.2019.103409>. Acesso em 22 jan.

**ANEXO A – DETALHAMENTO DO ESQUEMA DE VALIDAÇÃO CRUZADA PARA  
OS MÉTODOS INDIVIDUAIS BASEADOS EM APRENDIZADO DE MÁQUINA**

<b>MLP – Recurso Solar na Espanha</b>		
<b>Validação</b>	<b>Média do RMSE (W/m<sup>2</sup>)</b>	<b>nRMSE = Média do RMSE (W/m<sup>2</sup>)/ Média da Série de dados (W/m<sup>2</sup>)*</b>
<b>1</b>	62,148	0,093
<b>2</b>	59,258	0,089
<b>3</b>	63,478	0,095
<b>4</b>	77,125	0,116
<b>5</b>	<b>57,381</b>	<b>0,086</b>
<b>6</b>	59,987	0,090
<b>7</b>	65,248	0,098
<b>8</b>	58,369	0,088
<b>9</b>	75,287	0,113
<b>10</b>	65,268	0,098

<b>CFBP – Recurso Solar na Espanha</b>		
<b>Validação</b>	<b>Média do RMSE (W/m<sup>2</sup>)</b>	<b>nRMSE = Média do RMSE (W/m<sup>2</sup>)/ Média da Série de dados (W/m<sup>2</sup>)*</b>
<b>1</b>	52,248	0,078
<b>2</b>	<b>31,412</b>	<b>0,047</b>
<b>3</b>	35,487	0,053
<b>4</b>	40,988	0,062
<b>5</b>	37,564	0,056
<b>6</b>	45,874	0,069
<b>7</b>	32,963	0,049
<b>8</b>	50,174	0,075
<b>9</b>	35,255	0,053
<b>10</b>	42,689	0,064

RBF – Recurso Solar na Espanha		
Validação	Média do RMSE (W/m <sup>2</sup> )	nRMSE = Média do RMSE (W/m <sup>2</sup> )/ Média da Série de dados (W/m <sup>2</sup> )*
1	49,878	0,075
2	48,236	0,072
3	50,213	0,075
4	51,654	0,078
5	46,996	0,071
6	<b>45,738</b>	<b>0,069</b>
7	52,123	0,078
8	50,589	0,076
9	45,960	0,069
10	52,158	0,078

SOM– Recurso Solar na Espanha		
Validação	Média do RMSE (W/m <sup>2</sup> )	nRMSE = Média do RMSE (W/m <sup>2</sup> )/ Média da Série de dados (W/m <sup>2</sup> )*
1	92,568	0,139
2	<b>89,351</b>	<b>0,134</b>
3	90,265	0,136
4	95,677	0,144
5	100,655	0,151
6	97,589	0,147
7	101,113	0,152
8	70,998	0,107
9	89,836	0,135
10	103,459	0,155

---

**MLP– Recurso Eólico na Espanha**


---

<b>Validação</b>	<b>Média do RMSE (m/s)</b>	<b>nRMSE = Média do RMSE (m/s)/ Média da Série de dados (m/s)*</b>
<b>1</b>	<b>0,453</b>	<b>0,088</b>
<b>2</b>	0,593	0,115
<b>3</b>	0,658	0,128
<b>4</b>	0,858	0,167
<b>5</b>	0,599	0,116
<b>6</b>	0,745	0,144
<b>7</b>	0,523	0,102
<b>8</b>	0,660	0,128
<b>9</b>	0,780	0,151
<b>10</b>	0,489	0,095

---



---

**CFBP– Recurso Eólico na Espanha**


---

<b>Validação</b>	<b>Média do RMSE (m/s)</b>	<b>nRMSE = Média do RMSE (m/s)/ Média da Série de dados (m/s)*</b>
<b>1</b>	0,511	0,099
<b>2</b>	0,675	0,131
<b>3</b>	0,563	0,109
<b>4</b>	0,521	0,101
<b>5</b>	0,712	0,138
<b>6</b>	0,657	0,128
<b>7</b>	0,555	0,108
<b>8</b>	<b>0,493</b>	<b>0,096</b>
<b>9</b>	0,814	0,158
<b>10</b>	0,612	0,119

---

---

**RBF – Recurso Eólico na Espanha**


---

Validação	Média do RMSE (m/s)	nRMSE = Média do RMSE (m/s)/ Média da Série de dados (m/s)*
1	0,784	0,152
2	0,615	0,119
3	0,690	0,134
4	0,814	0,158
5	0,675	0,131
6	0,792	0,154
7	0,614	0,119
8	0,596	0,116
9	<b>0,575</b>	<b>0,112</b>
10	0,745	0,145

---



---

**SOM – Recurso Eólico na Espanha**


---

Validação	Média do RMSE (m/s)	nRMSE = Média do RMSE (m/s)/ Média da Série de dados (m/s)*
1	0,701	0,136
2	0,569	0,111
3	0,782	0,152
4	<b>0,553</b>	<b>0,107</b>
5	0,637	0,124
6	0,799	0,155
7	0,578	0,112
8	0,689	0,134
9	0,754	0,146
10	0,615	0,119

---

## MLP – Recurso Solar no Brasil

Validação	Média do RMSE (W/m <sup>2</sup> )	nRMSE = Média do RMSE (W/m <sup>2</sup> ) / Média da Série de dados (W/m <sup>2</sup> )*
1	90,587	0,212
2	89,963	0,211
3	95,265	0,223
4	91,558	0,215
5	100,659	0,236
6	96,337	0,226
7	90,594	0,212
8	90,555	0,212
9	<b>89,351</b>	<b>0,209</b>
10	93,475	0,219

## CFBP – Recurso Solar no Brasil

Validação	Média do RMSE (W/m <sup>2</sup> )	nRMSE = Média do RMSE (W/m <sup>2</sup> ) / Média da Série de dados (W/m <sup>2</sup> )*
1	75,269	0,176
2	70,963	0,166
3	<b>69,323</b>	<b>0,162</b>
4	72,569	0,170
5	80,975	0,190
6	74,201	0,174
7	71,222	0,167
8	70,900	0,166
9	74,589	0,175
10	70,578	0,165



---

**RBF – Recurso Solar no Brasil**


---

Validação	Média do RMSE (W/m <sup>2</sup> )	nRMSE = Média do RMSE (W/m <sup>2</sup> )/ Média da Série de dados (W/m <sup>2</sup> )*
<b>1</b>	<b>100,058</b>	<b>0,234</b>
2	110,256	0,258
3	111,556	0,261
4	115,878	0,271
5	105,069	0,246
6	114,124	0,267
7	102,987	0,241
8	103,111	0,242
9	103,998	0,244
<b>10</b>	<b>109,856</b>	<b>0,257</b>

---

**SOM – Recurso Solar no Brasil**


---

Validação	Média do RMSE (W/m <sup>2</sup> )	nRMSE = Média do RMSE (W/m <sup>2</sup> )/ Média da Série de dados (W/m <sup>2</sup> )*
<b>1</b>	<b>73,256</b>	<b>0,172</b>
2	70,989	0,166
3	80,115	0,188
4	72,326	0,169
5	79,113	0,185
6	81,236	0,190
7	<b>69,325</b>	<b>0,162</b>
8	72,900	0,171
9	74,253	0,174
<b>10</b>	<b>74,900</b>	<b>0,175</b>

---

<b>MLP– Recurso Eólico no Brasil</b>		
<b>Validação</b>	<b>Média do RMSE (m/s)</b>	<b>nRMSE = Média do RMSE (m/s)/ Média da Série de dados (m/s)*</b>
<b>1</b>	1,725	0,338
<b>2</b>	1,456	0,285
<b>3</b>	2,023	0,396
<b>4</b>	1,115	0,218
<b>5</b>	2,100	0,411
<b>6</b>	3,569	0,698
<b>7</b>	1,997	0,391
<b>8</b>	2,564	0,502
<b>9</b>	1,310	0,256
<b>10</b>	<b>0,910</b>	<b>0,178</b>

<b>CFBP– Recurso Eólico no Brasil</b>		
<b>Validação</b>	<b>Média do RMSE (m/s)</b>	<b>nRMSE = Média do RMSE (m/s)/ Média da Série de dados (m/s)*</b>
<b>1</b>	0,496	0,097
<b>2</b>	0,811	0,159
<b>3</b>	0,786	0,154
<b>4</b>	1,230	0,241
<b>5</b>	<b>0,399</b>	<b>0,078</b>
<b>6</b>	0,556	0,109
<b>7</b>	0,749	0,147
<b>8</b>	0,812	0,159
<b>9</b>	0,479	0,094
<b>10</b>	1,026	0,201

**RBF – Recurso Eólico no Brasil**

<b>Validação</b>	<b>Média do RMSE (m/s)</b>	<b>nRMSE = Média do RMSE (m/s)/ Média da Série de dados (m/s)*</b>
<b>1</b>	0,856	0,168
<b>2</b>	0,617	0,121
<b>3</b>	0,799	0,156
<b>4</b>	0,697	0,136
<b>5</b>	1,023	0,200
<b>6</b>	0,743	0,145
<b>7</b>	0,901	0,176
<b>8</b>	<b>0,515</b>	<b>0,101</b>
<b>9</b>	0,721	0,141
<b>10</b>	1,103	0,216

**SOM – Recurso Eólico no Brasil**

<b>Validação</b>	<b>Média do RMSE (m/s)</b>	<b>nRMSE = Média do RMSE (m/s)/ Média da Série de dados (m/s)*</b>
<b>1</b>	<b>0,615</b>	<b>0,120</b>
<b>2</b>	0,732	0,143
<b>3</b>	0,900	0,176
<b>4</b>	0,823	0,161
<b>5</b>	0,935	0,183
<b>6</b>	1,078	0,211
<b>7</b>	0,863	0,169
<b>8</b>	0,997	0,195
<b>9</b>	1,107	0,217
<b>10</b>	0,698	0,137

Descrição das arquiteturas, escolhidas de forma randômica, para realização da validação cruzada (3 *folds*) e para os diferentes métodos individuais e localidades:

- MLP

Validação	Entradas (quantidade de atrasos)	Camada Oculta (quantidade de neurônios)
1	6	6
2	6	4
3	8	3
4	10	8
5	6	5
6	8	7
7	12	7
8	10	6
9	8	4
10	4	4

- RBF

Validação	Entradas (quantidade de atrasos)	Camada Oculta (quantidade de neurônios)
1	5	5
2	7	7
3	10	7
4	9	6
5	8	4
6	4	6
7	6	9
8	6	4
9	4	7
10	8	10

- CFBP


		<b>Camada 1</b>	<b>Camada 2</b>
<b>Validação</b>	<b>Entradas (quantidade de atrasos)</b>	<b>(quantidade de neurônios)</b>	
<b>1</b>	8	4	3
<b>2</b>	5	5	4
<b>3</b>	6	3	2
<b>4</b>	10	6	4
<b>5</b>	4	2	4
<b>6</b>	9	5	3
<b>7</b>	7	7	5
<b>8</b>	5	3	4
<b>9</b>	6	4	2
<b>10</b>	9	5	3

- SOM


<b>Validação</b>	<b>Entradas (quantidade de atrasos)</b>	<b>Grade Bidimensional</b>
<b>1</b>	4	5*5
<b>2</b>	6	5*5
<b>3</b>	9	5*5
<b>4</b>	6	5*5
<b>5</b>	12	5*5
<b>6</b>	10	5*5
<b>7</b>	8	5*5
<b>8</b>	7	5*5
<b>9</b>	6	5*5
<b>10</b>	5	5*5

## ANEXO B – DETALHAMENTO DAS DIFERENTES SÉRIES DECOMPOSTAS POR MEIO DA DW


- **Dados eólicos no Brasil (decomposição em 6 níveis por meio de db4)**



- **Dados eólicos na Espanha (decomposição em 6 níveis por meio de db4)**



- **Dados solares no Brasil (decomposição em 5 níveis por meio de db10)**



- **Dados solares na Espanha (decomposição em 5 níveis por meio de db2)**

