



TAMBU MIGUEL ANTÓNIO

Licenciado em Engenharia de Telecomunicações

# MÉTODOS DE PREVISÃO DE PRODUÇÃO DE ENERGIA EÓLICA

MESTRADO EM ENGENHARIA DE ENERGIAS RENOVÁVEIS

Universidade NOVA de Lisboa  
Setembro, 2024

# MÉTODOS DE PREVISÃO DE PRODUÇÃO DE ENERGIA EÓLICA

**TAMBU MIGUEL ANTÓNIO**

Licenciado em Engenharia de Telecomunicações

**Júri:**

**Presidente:** Doutor Nuno Manuel Gonçalves Vilhena  
Professor Auxiliar, NOVA FCT

**Arguentes:** Doutor Nuno Manuel Ortega Amaro  
Professor Auxiliar, NOVA FCT

**Orientador:** Doutor Pedro Ribeiro Pereira  
Professor Auxiliar, NOVA FCT

## Métodos de previsão de produção de energia eólica

Copyright © Tambu Miguel António, Faculdade de Ciências e Tecnologia, Universidade NOVA de Lisboa.

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

## Dedicatória

*Dedico este trabalho a todos aqueles  
que, com seu apoio e incentivo, foram fundamen-  
tais para que eu me dedicasse e concluísse este  
mestrado*

# Agradecimentos

A concretização deste trabalho deve-se ao valioso apoio de várias pessoas e instituições, às quais expresso o meu profundo reconhecimento:

Primeiramente, agradeço ao meu orientador, Dr. Pedro Miguel Ribeiro Pereira, pela orientação e paciência durante todo o processo. Suas sugestões e conselhos foram essenciais para o desenvolvimento deste trabalho. Agradeço também aos professores e colegas do MEER, que contribuíram com seu conhecimento e críticas construtivas, o que garantiu êxito nesta pesquisa.

Estendo minha gratidão a Faculdade de Ciências e Tecnologias da Universidade Nova de Lisboa e ao Departamento de Engenharia Eletrotécnica e de Computadores, que me forneceram os recursos e o ambiente necessários para o desenvolvimento da minha dissertação.

Agradeço também ao Governo angolano, cujo apoio financeiro, através da bolsa de estudos concedida, foi fundamental para a realização deste mestrado. Sem esse suporte, não teria sido possível expandir meus conhecimentos e concluir este percurso acadêmico.

Finalmente, agradeço profundamente a Deus, aos meus familiares e amigos, que sempre estiveram ao meu lado com o seu apoio emocional, incentivo e compreensão. Aos meus pais, pelo seu amor e por acreditarem em mim, e aos amigos que compartilharam comigo os desafios e conquistas desta jornada.

A todos, o meu mais sincero agradecimento.

*"Na Natureza, nada se cria, nada se perde, tudo  
se transforma." (Lavoisier)*

## Resumo

À medida que o planeta enfrenta os desafios do aquecimento global, a procura por fontes de energia limpa surge como uma solução essencial. Neste contexto, a energia eólica destaca-se como uma alternativa significativa, devido à sua abundância e ao seu reduzido impacto ambiental. Como fonte de energia renovável, a energia eólica tem-se revelado bastante útil para a produção de energia elétrica, oferecendo vantagens consideráveis em relação a outras fontes, como a redução das emissões de CO<sub>2</sub> e os baixos custos operacionais. Contudo, a natureza intermitente e variável do vento apresenta desafios significativos para assegurar uma produção estável de energia elétrica. Para mitigar este problema, é essencial selecionar métodos de previsão precisos, de modo a garantir a eficiência operacional das turbinas ou parques eólicos e a integração eficaz da energia gerada por essas infraestruturas na rede elétrica.

A presente dissertação explora diversos métodos de previsão da produção de energia elétrica a partir de fontes eólicas. Com base numa revisão bibliográfica abrangente, foram analisados e descritos os principais métodos, destacando-se os métodos físicos (Previsão Numérica do Tempo), estatísticos (modelos autorregressivos de média móvel e redes neurais artificiais), o método de referência (Persistência) e os métodos híbridos. Foram também realçados os principais critérios de avaliação do desempenho destes métodos, nomeadamente o Erro Médio Absoluto, a Raiz do Erro Quadrático Médio e o Erro Percentual Absoluto Médio.

Por fim, foi desenvolvido um estudo de caso para aplicar um dos métodos descritos na previsão da produção de energia elétrica por meio eólico. O método escolhido foi uma rede neuronal do tipo Perceptrão Multicamadas, ou seja, uma rede *feedforward*, com duas camadas ocultas de 10 neurónios cada, utilizando o algoritmo de *backpropagation*. Esta configuração foi selecionada por ter demonstrado o melhor desempenho em comparação com outras. Os resultados da previsão para alguns dias dos meses de novembro e dezembro foram apresentados,

e o modelo implementado apresentou um bom desempenho ao realizar previsão a curto prazo, num horizonte temporal de 1h, com erros dentro de margens aceitáveis.

**Palavras-chave:** Energia renovável, vento, previsão de produção de energia, métodos de previsão, redes neurais artificiais, *feedforward*, *backpropagation*.

# Abstract

As the planet faces the challenges of global warming, the search for clean energy sources becomes essential. In this context, wind energy stands out as a significant alternative due to its abundance and low environmental impact. As a renewable energy source, wind energy has proven to be a promising solution for electricity generation, offering considerable advantages over other sources, such as reduced CO<sub>2</sub> emissions and low operational costs. However, the intermittent and variable nature of wind poses significant challenges in ensuring stable energy production. To address this issue, it is crucial to select accurate forecasting methods to ensure the operational efficiency of wind turbines or wind farms and the effective integration of the energy generated by these infrastructures into the electrical grid.

This dissertation explores various methods for forecasting wind energy production. Based on a comprehensive literature review, the main methods are analysed and described, including physical methods (Numerical Weather Prediction), statistical methods (autoregressive moving average models and artificial neural networks), the reference method (Persistence), and hybrid methods. The main performance evaluation criteria for these methods, such as MAE, RMSE, and MAPE, are also highlighted.

Finally, a case study was developed to apply one of the methods described for wind energy forecasting. The chosen method was a Multilayer Perceptron neural network, a feed-forward network with two hidden layers of 10 neurons each, using the backpropagation algorithm. This configuration was selected for its superior performance compared to others. The forecast results for several days in November and December were presented, and the implemented model showed good short-term forecasting performance, with errors within acceptable margins.

**Keywords:** Renewable energy, wind, energy production forecasting, forecasting methods, artificial neural networks, feedforward, backpropagation

# Índice

|          |                                               |          |
|----------|-----------------------------------------------|----------|
| <b>1</b> | <b>INTRODUÇÃO.....</b>                        | <b>1</b> |
| 1.1      | Descrição do problema.....                    | 3        |
| 1.2      | Motivação.....                                | 4        |
| 1.3      | Objectivos.....                               | 5        |
| 1.4      | Contribuições.....                            | 5        |
| 1.5      | Organização da Dissertação .....              | 6        |
| <b>2</b> | <b>ESTADO DA ARTE.....</b>                    | <b>6</b> |
| 2.1      | Recurso Eólico .....                          | 7        |
| 2.2      | Atlas Europeu do Vento.....                   | 8        |
| 2.2.1    | O Atlas Europeu do Vento Offshore.....        | 10       |
| 2.3      | Potência Eólica.....                          | 12       |
| 2.3.1    | Coeficiente de Potência .....                 | 13       |
| 2.3.2    | Curva de Potência do Gerador Eólico .....     | 14       |
| 2.4      | Previsão de Produção de Energia Eólica .....  | 15       |
| 2.4.1    | Principais Métodos de Previsão do Vento ..... | 15       |
| 2.4.1.1  | Métodos Físicos .....                         | 16       |
| 2.4.1.2  | Métodos Estatísticos .....                    | 16       |
| 2.4.1.3  | Método de Referência.....                     | 16       |
| 2.4.1.4  | Métodos Híbridos .....                        | 17       |
| 2.5      | Horizonte de Previsão do Vento.....           | 17       |

|          |                                                                        |           |
|----------|------------------------------------------------------------------------|-----------|
| 2.6      | Casos de Estudos Aplicados.....                                        | 19        |
| <b>3</b> | <b>MÉTODOS DE PREVISÃO .....</b>                                       | <b>25</b> |
| 3.1      | Previsão da Potência Eólica .....                                      | 25        |
| 3.2      | Classificação da Previsão de Energia Eólica.....                       | 26        |
| 3.2.1    | Métodos Físicos.....                                                   | 27        |
| 3.2.1.1  | Método NWP .....                                                       | 27        |
| 3.2.1.2  | Estatística de Saída do Modelo NWP - (MOS).....                        | 29        |
| 3.2.1.3  | Etapas de Previsão de Produção de Energia Eólica do Método Físico..... | 29        |
| 3.2.2    | Modelos Estatísticos .....                                             | 30        |
| 3.2.2.1  | Método ARMA .....                                                      | 32        |
| 3.2.2.2  | Método ANN ou ML .....                                                 | 36        |
| 3.2.2.3  | Redes Neuronal de Função de Base Radial - RBFNN.....                   | 42        |
| 3.2.2.4  | Estrutura e Algoritmo <i>Elman</i> (ENN) .....                         | 44        |
| 3.2.2.1  | Metodologia de Previsão .....                                          | 45        |
| 3.2.3    | Método de Referência - Persistência .....                              | 46        |
| 3.2.3.1  | Metodologia de Previsão .....                                          | 46        |
| 3.2.4    | Métodos Híbridos.....                                                  | 46        |
| 3.2.4.1  | Método CNN, RBFNN, DGF .....                                           | 50        |
| 3.2.4.2  | Método IF e DLNN .....                                                 | 50        |
| 3.2.4.3  | Método ARMA com Filtro de <i>Kalman</i> .....                          | 50        |
| 3.2.4.4  | Rede <i>Elman</i> com MLP.....                                         | 50        |
| 3.2.4.5  | Decomposição <i>Wavelet</i> e Rede <i>Elman</i> .....                  | 51        |
| 3.2.4.6  | Filtro de Kalman e MLP .....                                           | 51        |
| 3.3      | CrITÉRIOS para Avaliação dos Métodos de Previsão .....                 | 51        |
| 3.3.1    | Medição da Precisão .....                                              | 51        |
| 3.3.1.1  | Erro Normalizado .....                                                 | 52        |
| 3.3.1.2  | Erro Médio Percentual Absoluto - MAPE (%) .....                        | 52        |

|         |                                                                                                 |           |
|---------|-------------------------------------------------------------------------------------------------|-----------|
| 3.3.1.3 | Erro Absoluto Médio - MAE .....                                                                 | 53        |
| 3.3.1.4 | Raiz do Erro Quadrático Médio - RMSE.....                                                       | 53        |
| 3.3.1.5 | Erro Absoluto Médio Normalizado - NMAE.....                                                     | 53        |
| 3.3.1.6 | Raiz do Erro Quadrático Médio Normalizado - NRMSE.....                                          | 54        |
| 3.3.1.7 | Coefficiente de Determinação - R-Square ( <b>R<sup>2</sup></b> ) .....                          | 54        |
| 3.3.1.8 | Erro de Amplitude e de Fase.....                                                                | 55        |
| 3.3.2   | Tempo Computacional .....                                                                       | 58        |
| 3.3.3   | Parâmetros de Entrada.....                                                                      | 59        |
| 3.4     | Análise Comparativa Segundo os Critérios Utilizados .....                                       | 60        |
| 3.5     | Técnicas Implementadas para o Aperfeiçoamento da Precisão dos Métodos .....                     | 62        |
| 3.5.1   | <b>Filtro Kalman</b> .....                                                                      | 62        |
| 3.5.2   | <b>Deteção de Outliers</b> .....                                                                | 62        |
| 4       | <b>CASO DE ESTUDO: APLICAÇÃO DO MÉTODO ANN PARA PREVISÃO DE PRODUÇÃO DA ENERGIA EÓLICA.....</b> | <b>64</b> |
| 4.1     | Escolha e Justificativa do Método.....                                                          | 64        |
| 4.2     | Caracterização e Localização do Gerador Eólico.....                                             | 66        |
| 4.3     | Descrição do Software .....                                                                     | 67        |
| 4.4     | Pré-Processamento e Tratamento dos Dados.....                                                   | 68        |
| 4.5     | Implementação do Modelo de Previsão .....                                                       | 70        |
| 4.6     | Treino e Validação para Escolha da Melhor Configuração.....                                     | 72        |
| 5       | <b>ANÁLISE DOS RESULTADOS .....</b>                                                             | <b>80</b> |
| 5.1     | Previsão da Produção para o Mês de Novembro .....                                               | 80        |
| 5.2     | Previsão da Produção para o Mês de Dezembro.....                                                | 85        |
| 6       | <b>CONCLUSÕES E RECOMENDAÇÕES.....</b>                                                          | <b>90</b> |
| 6.1     | Conclusões .....                                                                                | 90        |
| 6.2     | Recomendações .....                                                                             | 92        |
| 7       | <b>BIBLIOGRAFIA.....</b>                                                                        | <b>94</b> |

## Índice de Figuras

|                                                                                                                                                                                        |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1.1 - Estatística da Potência Instalada das Energias Renováveis em Portugal (DGEG, 2024).....                                                                                   | 3  |
| Figura 2.1- Velocidades médias anuais do vento e recursos de energia eólica sobre a Europa (países da UE) combinando atlas de vento terrestre e offshore (Troen & Petersen, 1989)..... | 9  |
| Figura 2.2 - Atlas Europeu do vento offshore (fonte: globalwindatlas) .....                                                                                                            | 11 |
| Figura 2.3: Atlas Português do Vento (m/s) média horizontal do vento 60 m (fonte: globalwindatlas). .....                                                                              | 12 |
| Figura 2.4 - Curva de potência da turbina eólica Enercon E40–500 kW (Adaptado de Lima et al., 2017) .....                                                                              | 14 |
| Figura 2.5-Classificação dos Principais métodos de Previsão .....                                                                                                                      | 17 |
| Figura 3.1: Cubos tridimensionais da atmosfera utilizados pelos modelos NWP (Al-Yahyai et al., 2010) .....                                                                             | 28 |
| Figura 3.2- Caixa de Grelha (Al-Yahyai et al., 2010).....                                                                                                                              | 28 |
| Figura 3.3 - Principais Etapas do Método Físico (Monteiro et al., 2009).....                                                                                                           | 30 |
| Figura 3.4- Etapas do Método Estatístico (Monteiro et al., 2009) .....                                                                                                                 | 31 |
| Figura 3.5 - Metodologia de previsão usando o método ARMA.....                                                                                                                         | 34 |
| Figura 3.6- Estrutura de uma ANN do tipo Percetrão ( Hanifi et al., 2020).....                                                                                                         | 40 |
| Figura 3.7- Funcionamento básico de cada unidade de uma rede do tipo perceptrão multicamada (Castro, 2018) .....                                                                       | 40 |
| Figura 3.8 - Fluxograma do Algoritmo MLP - <i>Backpropagation</i> (Xu & Mao, 2016) .....                                                                                               | 41 |
| Figura 3.9 - Estrutura da rede RBFNN para previsão de energia eólica (C. Zhang et al., 2016) .....                                                                                     | 43 |
| Figura 3.10 - Estrutura da rede neuronal <i>Elman</i> (Xu & Mao, 2016).....                                                                                                            | 44 |
| Figura 3.11-Fluxograma de métodos de combinação (adaptado d B. Yang et al., 2021) .....                                                                                                | 47 |

|                                                                                                                                                   |    |
|---------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 3.12- Pré-processamento de dados (Adaptado de Yang et al., 2021) .....                                                                     | 48 |
| Figura 3.13- Seleção e otimização de parâmetros do modelo (Adaptado de Yang et al., 2021) .....                                                   | 48 |
| Figura 3.14 - Abordagem combinada baseada em pós-processamento (Adaptado de Yang et al., 2021) .....                                              | 48 |
| Figura 3.15 - Erros da amplitude e fase da Previsão de Energia Eólica (Jyothi & Rao, 2016)..                                                      | 55 |
| Figura 3.16 - Relatório da precisão da produção de energia eólica Abril de 2021 (fonte: EirGrid & SONI).....                                      | 58 |
| Figura 3.17 - Relatório da precisão da produção de energia eólica Maio de 2021 (fonte: EirGrid & SONI).....                                       | 58 |
| Figura 3.18- Estatísticas dos parâmetros de entrada (Hanifi et al., 2020) .....                                                                   | 60 |
| Figura 4.1- Etapas para a implementação do caso de estudo.....                                                                                    | 64 |
| Figura 4.2 - Curva característica do gerador eólico modelo FD3.6-2000L.10L (Rogado, 2018)                                                         | 66 |
| Figura 4.3 - Gerador eólico modelo FD3.6-2000L.10L (Rogado, 2018).....                                                                            | 67 |
| Figura 4.4 - Dados históricos das amostras da velocidade do vento (m/s) .....                                                                     | 69 |
| Figura 4.5 -Dados Históricos das Amostras da Potência Produzida .....                                                                             | 69 |
| Figura 4.6 - Análise Gráfica do Desempenho das Diferentes Configurações da Camada Oculta .....                                                    | 73 |
| Figura 4.7 - Análise Gráfica do Desempenho das Diferentes Configurações da Camada Oculta .....                                                    | 75 |
| Figura 4.8- Estrutura da Rede Neuronal <i>Feedforward</i> .....                                                                                   | 76 |
| Figura 4.9 - Análise de Desempenho do Modelo de Regressão: Comparação entre o Valores Reais e Saídas Previstas na fase de Treino e Validação..... | 77 |
| Figura 4.10 - Treino: Real vs. Previsto .....                                                                                                     | 78 |
| Figura 4.11 - Validação: Real vs. Previsto .....                                                                                                  | 78 |
| Figura 5.1- Previsão da Potência para o dia 7 e 9 de novembro .....                                                                               | 82 |
| Figura 5.2 -Previsão da Potência para o dia 14 e 15 de novembro .....                                                                             | 84 |
| Figura 5.3 - Previsão da Potência para o dia 1 e 2 de Dezembro .....                                                                              | 87 |
| Figura 5.4 - Previsão da Potência para o dia 14 e 15 de Dezembro .....                                                                            | 89 |

## Índice de Tabelas

|                                                                                                          |    |
|----------------------------------------------------------------------------------------------------------|----|
| Tabela 2.1 - Classificação do horizonte temporal para previsão de energia eólica .....                   | 18 |
| Tabela 3.1 - Métodos de previsão de produção de energia eólica em séries temporais .....                 | 35 |
| Tabela 3.2 - Diferentes algoritmos de previsão de energia eólica ANN .....                               | 37 |
| Tabela 3.3 - Alguns Modelos Híbridos utilizados para previsão do vento .....                             | 49 |
| Tabela 3.4 - Avaliação de desempenhos dos métodos de previsão com base as métricas estatísticas .....    | 55 |
| Tabela 3.5- Abordagem comparativa dos métodos de previsão da energia .....                               | 61 |
| Tabela 4.1- Estatísticas Resumidas das Amostras de Velocidade do Vento .....                             | 69 |
| Tabela 4.2 - Estatísticas Resumidas das Amostras da Potência Produzida .....                             | 70 |
| Tabela 4.3 - Desempenho das diferentes configurações da camada oculta na fase de treino..                | 72 |
| Tabela 4.4 - Desempenho das Diferentes Configurações da Camada Oculta na Fase de Validação .....         | 74 |
| Tabela 5.1- Resultados da Previsão da Produção para os dias 7 e 9 de Novembro (horizonte de 1h) .....    | 81 |
| Tabela 5.2 - Resultados da Previsão da Produção para os dias 14 e 15 de Novembro (horizonte de 1h) ..... | 83 |
| Tabela 5.3 - Resultados dos critérios de avaliação para os dois períodos analisados em Novembro .....    | 85 |
| Tabela 5.4 - Resultados da Previsão da Produção para os dias 1 e 2 de Dezembro (horizonte de 1h) .....   | 85 |
| Tabela 5.5 - Resultados da Previsão da Produção para os dias 14 e 15 de Dezembro (horizonte de 1h) ..... | 87 |
| Tabela 5.6 - Resultados dos critérios de avaliação para os dois períodos analisados em Dezembro .....    | 89 |

## Siglas

FER – Fontes de Energia Renováveis

NWP – *Numerical Weather Prediction* / Previsão Numérica do Tempo

SCADA – *Supervisory Control and Data Acquisition* / Supervisão, Controlo e Aquisição de Dados

MOS – *Model Output Statistics* / Estatísticas de Saída de Modelos

ARMA – *Autoregressive Moving Average* / Média Móvel Auto-regressiva

ARIMA – *Autoregressive Integrated Moving Average* / Média Móvel Auto-regressiva Integrada

ARX – *Autoregressive with Exogenous Inputs* / Auto-regressivo com Entradas Exógenas

ANN – *Artificial Neural Network* / Rede Neuronal Artificial

MLP – *Multilayer Perceptron* / Perceptron Multicamadas

BPNN – *Backpropagation Neural Network* / Rede Neuronal com Retropropagação

ML – *Machine Learning* / Aprendizagem Automática

RBFNN – *Radial Basis Function Neural Network* / Rede Neuronal de Função de Base Radial

ENN – *Elman Neural Network* / Rede Neuronal de Elman

WNN – *Wavelet Neural Network* / Rede Neuronal Wavelet

CNN – *Convolutional Neural Network* / Rede Neuronal Convolucional

LSTM – *Long Short-Term Memory* / Memória de Curto e Longo Prazo

AWNN – *Adaptive Wavelet Neural Network* / Rede Neuronal Wavelet Adaptativa

MAPE – *Mean Absolute Percentage Error* / Erro Percentual Absoluto Médio

MAE – *Mean Absolute Error* / Erro Absoluto Médio

RMSE – *Root Mean Square Error* / Raiz do Erro Quadrático Médio

MSE – *Mean Squared Error* / Erro Quadrático Médio

NMAE – *Normalized Mean Absolute Error* / Erro Absoluto Médio Normalizado

NRMSE – *Normalized Root Mean Square Error* / Raiz do Erro Quadrático Médio Normalizado

$R^2$  – *Coefficient of Determination* / Coeficiente de Determinação

AE – *Absolute Error* / Erro Absoluto

APE – *Absolute Percentage Error* / Erro Percentual Absoluto

SDE – *Standard Deviation Error* / Erro do Desvio Padrão

MFNN–GA – *Multilayer Feedforward Neural Network with Genetic Algorithm* / Rede Neuronal de Alimentação Direta Multicamadas com Algoritmo Genético

RBFFNN–GA – *Radial Basis Function Neural Network with Genetic Algorithm* / Rede Neuronal de Função de Base Radial com Algoritmo Genético

RBFFNN–DGF – *Radial Basis Function with Differential Gaussian Functions* / Rede Neuronal de Função de Base Radial com Funções Gaussianas Diferenciais

CNN–MFNN – *Convolutional Neural Network and Multilayer Feedforward Neural Network* / Rede Neuronal Convolutacional e Rede Neuronal de Alimentação Direta Multicamadas

CNN–RBFFNN – *Convolutional Neural Network and Radial Basis Function Neural Network* / Rede Neuronal Convolutacional e Rede Neuronal de Função de Base Radial

DGF – *Differential Gaussian Functions* / Funções Gaussianas Diferenciais

DLNN – *Deep Learning Neural Network* / Rede Neuronal de Aprendizagem Profunda.

## Símbolos

- $Y_t$  – Representa a série temporal que se pretende descrever no instante  $t$ ;
- $c$  – É a constante do modelo;
- $\varepsilon_t$  – Representa o ruído branco (em um termo de erro, variável aleatório);
- $\varphi_i$  – Representa os parâmetros AR do modelo (números reais);
- $\mu$  – É a constante do modelo (normalmente tida como nula, ou valor esperado);
- $\theta_i$  – Representa os parâmetros da média móvel (números reais);
- $p$  – Ordem do processo auto-regressivo;
- $q$  – Ordem do processo de média móvel;
- $d$  – Ordem do processo integrado;
- $L$  – Operador de atraso;
- $\varphi(x)$  – Representa a saída da rede neural de função de base radial (RBFNN);
- $w_i$  – Peso associado ao neurónio da camada oculta;
- $\rho$  – é a função de base radial (função gaussiana);
- $Y_N(t, l)$  - É o valor medido normalizado no instante  $t$  (é o valor medido do banco de dados SCADA);
- $Y_N^*(t, l)$  - É o valor previsto normalizado para instante  $t$ ;
- $l$  - Indica o horizonte de tempo de previsão, e salientar que  $t$  representa hora dos dados medidos e previstos;
- $Y_i^*$  – é o valor previsto;
- $Y_{-i}$  é o valor real;
- $E_{cin}$  – Energia cinética (J);
- $A$  – é a secção plana transversal ( $m^2$ );
- $m$  – Massa do ar (kg);
- $x$  – Espessura do volume do ar (m);

$P_{disp}$  – Potência disponível no vento (W);

$\rho$  – Massa volúmica (densidade) do ar ( $\text{kg/m}^3$ );

$v_{\infty}$  – Velocidade do vento uniforme ou não perturbada (m/s);

$C_p$  – Coeficiente de Potência;

$P_e$  – Potência elétrica (w);

## INTRODUÇÃO

Globalmente, tem-se verificado uma crescente consciencialização sobre a importância de promover o desenvolvimento sustentável. No contexto da produção de energia elétrica, tal implica equilibrar a oferta com a procura (consumo) responsável, a proteção do meio ambiente e consequentemente a melhoria na qualidade de vida no planeta.

Esta consciencialização surge com objetivo de dar resposta aos significativos impactos ambientais negativos provocados pela atividade humana, especialmente o aquecimento global resultante das emissões de gases de efeito estufa provocada pela queima de combustíveis fósseis. Simultaneamente, subsiste uma preocupação crescente com o eventual esgotamento, a médio prazo, das reservas de recursos naturais, como o carvão e o petróleo (Abisoye et al., 2024).

O desenvolvimento sustentável coloca um desafio considerável: é necessário minimizar os impactos ambientais enquanto se mantém o crescimento económico. Isto significa que, por um lado, é imperativo gerar energia suficiente para atender às necessidades atuais e, por outro, realizar essa transição sem esgotar os recursos necessários para as futuras gerações. Nesse contexto, a mudança para fontes de energia renováveis assume uma importância global, e Portugal segue essa mesma tendência (APA, 2023).

Em Portugal, uma parte significativa de energia elétrica provém de fontes renováveis, especialmente de centrais hidroelétricas (APA, 2023). Contudo, a expansão desta fonte enfrenta desafios, nomeadamente a dificuldade de justificar o alagamento de grandes áreas para a construção de novas barragens. Isto reforça a necessidade de explorar alternativas mais sustentáveis e viáveis.

Neste contexto, a energia elétrica proveniente de fontes eólica tem emergido como uma opção ideal para uma transição energética sustentável e tem evidenciado um notável progresso nos últimos anos (Khodayar et al., 2022). Esta forma de energia baseia-se na conversão da energia cinética do vento em energia elétrica. A energia cinética disponível no vento, ao movimentar as pás dos aerogeradores, faz com que o rotor gira, convertendo-a energia mecânica que, posteriormente, é convertida em energia elétrica através do gerador elétrico.

A produção de energia numa turbina eólica depende de três fatores principais: a área do rotor, a densidade do ar e, principalmente, a velocidade e direção vento. Embora a densidade do ar e a área do rotor sejam relativamente constantes e pouco afetadas pela localização geográfica, a velocidade do vento varia significativamente de acordo com a temperatura, a pressão atmosférica e as características do terreno (Castro, 2018).

Portugal possui um vasto potencial eólico, principalmente nas regiões costeiras e montanhosas. De acordo com o Costa (2004) e o Atlas de Potencial Eólico de Portugal, existem diversas áreas no país onde é possível observar velocidade média do vento superior a 7 m/s. Em 2023, a capacidade instalada de energia elétrica proveniente dos parques eólicos em Portugal ultrapassou os 5,73 GW, como pode ser observado na figura 1.1, o que demonstra um crescimento sólido e contínuo desta FER (DGEG, 2024).

Com o crescimento da capacidade instalada de geração de energia eólica, tanto em Portugal como em outras partes de mundo, torna-se então fundamental prever com precisão a produção de energia elétrica gerada por aerogeradores e parques eólicos. Esta previsão é essencial para otimizar a operação, manutenção e integração da energia elétrica gerada pela esta fonte na rede, dado que a produção eólica depende fortemente das condições meteorológicas, em particular da velocidade do vento, que apresenta características instáveis e variáveis. Devido a essa instabilidade, torna-se crucial aplicar métodos de previsão eficazes, capazes de estimar com precisão a quantidade de energia que será fornecida.

Desta forma, a presente dissertação tem como objetivo explorar e descrever diversos métodos de previsão da produção de energia eólica, bem como avaliar o desempenho de cada um. Com base nas pesquisas feitas e nos critérios de avaliação de desempenhos de cada método estabelecidos, será selecionado aquele que melhor se adequa ao cenário em análise. Esse método será então aplicado num estudo de caso focado na produção de um gerador eólico

com capacidade de 2 kW, instalado na Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa.




Figura 1.1 - Estatística da Potência Instalada das Energias Renováveis em Portugal (DGEG, 2024)

## 1.1 Descrição do problema

A crescente importância da energia eólica para uma transição energética eficiente, enfrenta desafios significativos devido à natureza intermitente do vento. As flutuações na velocidade e direção do vento impactam diretamente na entrega de potência elétrica das turbinas eólicas à rede elétrica, que resulta em custos elevados de operação devido à imprevisibilidade na produção de energia elétrica. Além disso, a variabilidade climática e as características locais do terreno tornaram a produção de energia elétrica por meio eólico um desafio em muitas regiões ao redor mundo. Esses desafios comprometem a confiabilidade e a eficiência da energia eólica como fonte de energia renovável.

O sistema de energia elétrica tem uma característica única que os diferenciam de outros sistemas, e a mais importante e desafiador é que em cada instante, a produção deve ser igual a procura (consumo) somado das perdas. E para se cumprir a esses desafios, é obrigado que as centrais selecionados a fornecerem o consumo numa determinada hora sejam selecionadas através do pré-despacho. Entretanto, o comportamento variável no tempo da produção eólica

induz alterações no pré-despacho das centrais elétricas e perturba a capacidade de transmissão entre as regiões. E se a variação da potência elétrica não for prevista ou for erradamente prevista, será necessário colocar em serviço unidades de reserva, que podem ser muito caras, para compensar rapidamente o desequilíbrio entre a geração e a carga.

Outro problema existente, está relacionado com funcionamento dos mercados de energia, por exemplo o MIBEL. No âmbito destes, os produtores são obrigados a indicar, com antecedência, a quantidade de energia elétrica que vão oferecer para o mercado, numa determinada hora, havendo lugar a penalização em caso de incumprimento. Diante deste dilema, surge a real necessidade de pesquisar, compreender e desenvolver métodos de previsão de produção de energia eólica capazes de prever com precisão a energia elétrica que será produzida pelos geradores ou parques eólicos num determinado período.

## **1.2 Motivação**

A transição para fontes de energia renovável, com destaque para a energia eólica, desempenha um papel crucial na busca por soluções sustentáveis para atender à crescente procura de energia. A contribuição significativa dessas fontes para a matriz energética destaca a necessidade urgente de otimizar a sua integração eficaz no sistema elétrico. Contudo, a variabilidade inerente à geração de energia eólica torna essencial a implementação de métodos avançados de previsão para garantir a estabilidade e eficiência operacional. Neste contexto, este trabalho propõe-se a explorar métodos de previsão de produção de energia eólica, com foco especial nos principais métodos existentes. Ao enfrentar os desafios complexos impostos pela natureza instalável da energia eólica, pretende-se oferecer uma contribuição valiosa para a eficiência do sistema elétrico, de modo a melhorar a sua capacidade de planeamento, manutenção e operação.

A revisão da literatura destaca as limitações dos métodos tradicionais e realça o potencial promissor no uso das redes neuronais artificial e modelos híbridos mais avançados. Ao analisar estudos recentes e inovações no campo, esta dissertação visa não apenas apresentar uma perspetiva abrangente das metodologias existentes, mas também aplicar através de um caso de estudo um método de previsão que integra configurações eficientes para realizar

previsão em cenários específicos. Ao fornecer *insights* valiosos sobre como enfrentar os desafios associados à previsão de energia eólica, este trabalho visa contribuir significativamente para a integração bem-sucedida dessa fonte de energia crucial no cenário energético global.

### 1.3 Objectivos

O objetivo principal da presente dissertação é realizar uma análise abrangente por meio de um levantamento bibliográfico exaustivo de métodos de previsão de produção de energia elétrica através de fonte eólica (vento).

Este trabalho, pretende classificar e categorizar as técnicas de previsão existentes com foco aos métodos físicos, estatísticos, inteligência artificial, e outros métodos relevantes, bem como investigar e analisar os fatores que impactam a precisão desses métodos de previsões, como variações sazonais, topografia local e características específicas do parque eólico.

Fazer uma análise comparativa entre os métodos existentes, identificar as suas vantagens, limitações e aplicabilidade em cenários específicos de previsão de produção de energia eólica.

E por fim, selecionar um método de previsão que apresentar as características e desempenho ideal para aplicar em um caso de estudo. Esta simulação visa prever a potência elétrica do gerador eólico instalado na Faculdade de Ciências e Tecnologias da Universidade Nova de Lisboa.

### 1.4 Contribuições

Estudar a previsão da produção de energia eólica por meio dos métodos existentes trará uma contribuição científica e energética muito importante. Em primeiro lugar, a pesquisa científica nessa área ajudará a aperfeiçoar os métodos de previsão existentes, e permitir com que se tenha uma estimativa mais precisa da quantidade de potência elétrica que pode ser gerada pelas turbinas ou parques eólicos. O que é crucial para o planeamento e operação do mercado das energias.

Além disso, uma melhor previsão de produção de energia eólica traz benefícios energéticos significativos. Com uma estimativa mais precisa, é possível otimizar o uso da energia

eólica, de maneira a evitar desperdícios e garantir um fornecimento estável e confiável desta fonte.

Desta feita, a presente dissertação contribuirá para o avanço científico na área de previsão de produção de energia eólica e trará benefícios energéticos, que ajudarão a maximizar a eficiência e o uso sustentável dessa fonte renovável.

## **1.5 Organização da Dissertação**

No Capítulo 1, contextualiza-se o trabalho, destacando sua relevância e é apresentado a descrição do problema a ser abordado. Além disso, são delineados os principais objetivos do projeto, contribuições juntamente com a motivação subjacente ao estudo.

No Capítulo 2, realiza-se o estado da arte do problema, é efetuado uma revisão teórica sobre os principais artigos científicos e autores que abordam trabalhos semelhantes, bem como suas contribuições na área em estudo. Também é conduzida uma análise dos principais métodos de previsão atualmente utilizados.

No Capítulo 3, será realizada uma descrição detalhada dos métodos de previsão produção de energia eólica e uma análise comparativa dos principais métodos de previsão, levando em consideração as características de precisão de cada modelo.

No Capítulo 4, será selecionado o método que apresentar o menor erro de precisão, ou seja, o mais eficaz, para realizar um estudo de caso em uma zona específica, e os resultados serão analisados em detalhe.

No Capítulo 5, serão apresentados os resultados do caso de estudo.

No Capítulo 6, serão apresentados as conclusões e recomendações.

## ESTADO DA ARTE

Neste capítulo, serão abordados os conceitos fundamentais necessários para o desenvolvimento trabalho, baseando-se nas contribuições dos principais artigos científicos e autores. Além disso, serão exploradas outras informações relevantes relacionadas à proposta em discussão.

### 2.1 Recurso Eólico

De acordo com Castro (2018), o vento é um fenômeno causado por diferenças de pressão ao longo da superfície terrestre, decorrentes do fato de a radiação solar recebida na Terra ser maior nas zonas equatoriais do que nas zonas polares. Portanto, a origem do vento está relacionada à radiação solar. Segundo Burton et al. (2001), a potência disponível no vento varia com o cubo da velocidade do vento, sendo crucial compreender as características do recurso eólico em todos os aspectos da exploração da energia eólica. Os mesmos autores sustentam ainda que a característica mais marcante do recurso eólico é a sua variabilidade. O vento é altamente variável, tanto geograficamente quanto temporalmente. Essa variabilidade persiste em uma ampla gama de escalas, tanto no espaço quanto no tempo.

Os ventos mais fortes, constantes e persistentes ocorrem em faixas situadas a cerca de 10 km da superfície da Terra. No entanto, não é possível instalar os conversores eólicos nessas zonas, uma vez que o espaço de interesse está limitado a algumas dezenas de metros na atmosfera. A esta altitude, o vento é diretamente afetado pela fricção na superfície, o que resulta numa diminuição da sua velocidade (Castro, 2018).

Numa escala ampla, a variabilidade espacial do vento destaca-se pela presença de diversas regiões climáticas no mundo, algumas mais propícias à produção de energia eólica do que outras. Estas regiões são fortemente influenciadas pela latitude, que impacta a quantidade de insolação. A nível climático, variações menores são ditadas pela geografia física, incluindo proporção de terra e mar, dimensão de massas terrestres e presença de montanhas ou planícies. A topografia local desempenha um papel crucial na dinâmica do vento, com áreas mais elevadas a registar ventos de maior intensidade, enquanto zonas mais abrigadas, como vales, apresentam ventos de menor intensidade devido à presença de obstáculos, como árvores ou edifícios (Burton et al., 2001).

Diante deste facto, para se ter uma avaliação precisa do potencial eólico na geração de energia eléctrica, é necessário recorrer a medições específicas de vento. No entanto, segundo Castro (2018), os estudos iniciais não contavam com esses dados dedicados. As informações disponíveis provinham de estações meteorológicas destinadas a outros fins, como aviação e agricultura, não sendo ideais para essa finalidade. Isso resultava em avaliações subestimadas do potencial eólico, uma vez que as estações não estavam localizadas nos locais mais propícios para captar vento.

## **2.2 Atlas Europeu do Vento**

Na europa, uma das primeiras ações com vista à correção desta situação foi a publicação, em 1989, do "Atlas Europeu do Vento". Os dados foram obtidos a partir de estações meteorológicas selecionados, sendo depois corrigidos, embora de forma grosseira, para ter em conta os efeitos da topografia, e finalmente, extrapolados para outras áreas (Castro, 2018).

O documento inclui mapas de várias áreas da União Europeia, como indicado na Figura 2.1, que apresentam a velocidade média anual do vento a 50 metros acima do nível do solo, considerando cinco condições topográficas distintas: terreno protegido, planície aberta, costa marítima, mar aberto, e colinas e cristas (Troen & Petersen, 1989).




Figura 2.1- Velocidades médias anuais do vento e recursos de energia eólica sobre a Europa (países da UE) combinando atlas de vento terrestre e offshore (Troen & Petersen, 1989)

Cada cor apresentada no mapa está associada a uma classe de velocidade do vento, e à densidade de potência do vento ( $W/m^2$ ). As cores quentes como o vermelho e o laranja, representam áreas com as maiores velocidades do vento e, conseqüentemente, com o maior potencial para aproveitamento de energia eólica. Estas áreas incluem regiões costeiras do norte da Europa, como o Reino Unido e a Noruega, onde os ventos são fortes e consistentes, favorecendo a produção de energia eólica. Estas regiões são ideais para a instalação de turbinas eólicas devido à sua elevada densidade de potência (Castro, 2018; Enevoldsen et al., 2019).

Por outro lado, as cores frias como o verde e o azul, representam regiões com menor potencial eólico. Estas áreas encontram-se principalmente nas regiões centrais e meridionais da Europa, como em partes de Espanha e Itália, onde a velocidade do vento é consideravelmente mais baixa. Nestas regiões, a geração de energia eólica pode ser menos eficiente, sendo necessário avaliar outros fatores para a viabilidade de projetos eólicos.

A tabela abaixo do mapa classifica as velocidades do vento e a densidade de potência em cinco tipos de terreno. Por exemplo, o terreno protegido refere-se a áreas com muitos obstáculos, como árvores ou edifícios, que reduzem significativamente a velocidade do vento. Planícies abertas são áreas planas, sem barreiras, que apresentam ventos mais consistentes. As áreas junto à costa marítima tendem a beneficiar de ventos mais fortes, devido à ausência de obstáculos, e o mar aberto representa as regiões com os ventos mais intensos, sem qualquer barreira física. Por último, as colinas e cristas são zonas elevadas onde o vento acelera devido à topografia.

Cada classe de vento está associada a diferentes intervalos de velocidade do vento e densidade de potência. Por exemplo, no mar aberto, a classe de vento mais alta (tipo 5) tem velocidades superiores a 9,0 m/s e densidades de potência superiores a 800 W/m<sup>2</sup>, o que representa um excelente potencial para geração de energia elétrica.

Quanto a Portugal, a maior parte continental é classificada como classe 2, com apenas pequenas faixas costeiras a Oeste e ao Sul identificadas como tipo 3. Conforme indicado na legenda da Figura 2.1, para a zona tipo 2, as velocidades médias anuais do vento variam entre 3,5-4,5 m/s (terreno abrigado), enquanto para a zona tipo 3, as velocidades médias anuais do vento variam entre 7,0-8,5 m/s (terreno montanhoso), dependendo do tipo de terreno em questão.

Apesar de suas limitações, Castro (2018) afirma que o "Atlas Europeu do Vento" representou um esforço significativo para desenvolver um instrumento válido na previsão da produção de energia elétrica com base no potencial eólico.

### **2.2.1 O Atlas Europeu do Vento Offshore**

O potencial eólico offshore é delineado no "Atlas Europeu do Vento Offshore", conforme mostrado na Figura 2.2 e como pode ser verificado, os recursos mais significativos estão

concentrados em torno das ilhas Britânicas, onde as velocidades médias anuais podem exceder 10 m/s a uma altura de 100 m.




Figura 2.2 - Atlas Europeu do vento offshore (fonte: [globalwindatlas](http://globalwindatlas.com))

Em Portugal, a energia eólica offshore mostra-se com valores moderados, a costa portuguesa caracteriza-se por apresentar, em geral, velocidades médias do vento de aproximadamente 8 m/s a uma altura de 100 metros. Esses valores superam as velocidades do vento observadas em áreas terrestres. Uma versão abrangente do "Atlas Português do Vento" está disponível na figura 2.2. As maiores velocidades médias anuais (variando de 6 a 7 m/s a uma altura de 60 metros) são encontradas ao longo do litoral oeste, especialmente na região central, e em algumas áreas do interior norte (Castro, 2018).




Figura 2.3: Atlas Português do Vento (m/s) média horizontal do vento 60 m (fonte: [globalwindatlas](http://globalwindatlas.com)).

Com base na revisão bibliográfica sobre a natureza do vento, torna-se então fundamental analisar o seu comportamento para obter previsões precisas de sua ocorrência nesses locais com maior potencial eólico.

## 2.3 Potência Eólica

Para que a energia do vento possa ser aproveitada de forma eficiente, é fundamental que exista um fluxo de vento contínuo e com uma intensidade considerável. Os aerogeradores atuais são projetados para atingir a potência máxima, conhecida como potência nominal, em velocidades de vento que variam entre 13 e 16 m/s (Castro, 2018). A energia disponível para uma turbina eólica corresponde à energia cinética associada a um volume de ar, com a sua respetiva massa, que se move a uma velocidade uniforme e constante, tal como ilustrado na equação 2.1:

$$E_{cin} = \frac{1}{2}mv_{\infty}^2 = \frac{1}{2}\rho A x v_{\infty}^2 \quad 2.1$$

Onde:  $E_{cin}$ , representa a energia cinética do vento (J),  $m$  a massa do ar (kg),  $v_{\infty}$  velocidade do vento não perturbado,  $\rho$  a densidade do ar ( $\text{kg/m}^3$ ),  $x$  a espessura do volume do ar (m) e  $A$  é a secção plana transversal ( $\text{m}^2$ ).

A potência disponível no vento é, assim, proporcional ao cubo da velocidade do vento, como demonstrado na equação 2.2.

$$P_{disp} = \frac{1}{2} \rho A v_{\infty}^3 \quad 2.2$$

Como se pode observar na equação 2.2, a potência disponível é fortemente dependente da velocidade do vento: quando esta duplica, a potência aumenta em oito vezes. Em contrapartida, se duplicarmos a área varrida pelas lâminas da turbina, o aumento da potência é apenas de duas vezes. Além disso, se a velocidade do vento diminuir para metade, a potência reduz-se a 12,5%. Outro especto relevante a ser observado na equação é a dependência da densidade do ar, que é fortemente influenciada pela variação da temperatura, segundo o Castro (2018), a potência do vento diminui com o aumento da temperatura.

### 2.3.1 Coeficiente de Potência

A equação 2.2 representa a potência disponível no vento na ausência da turbina eólica. Contudo, essa potência não pode ser totalmente convertida em potência mecânica no eixo da turbina, uma vez que o ar, ao passar pelo plano das lâminas, precisa sair com uma velocidade diferente de zero. Uma turbina ideal poderá extrair, no máximo, cerca de 59,3% da potência disponível no vento este limite é conhecido como limite de Betz (Burton et al., 2001). No entanto, as turbinas eólicas modernas conseguem converter, na melhor das hipóteses, entre 48% e 50%, o que representa, assim, até 80% do máximo teórico (Castro, 2018).

Assim, o coeficiente de potência é um parâmetro fundamental na análise de turbinas eólicas, que mede a eficiência com que uma turbina converte a potência do vento em potência mecânica. É definido como a razão entre a potência elétrica gerada pela turbina e a potência disponível no vento, conforme ilustrado pela equação 2.3:

$$C_p = \frac{P_e}{P_{disp}} \quad 2.3$$

Onde:  $C_p$  representa o coeficiente de Potência,  $P_e$  Potência elétrica (W) e  $P_{disp}$  a Potência disponível no vento (W).

### 2.3.2 Curva de Potência do Gerador Eólico

A curva de potência de um gerador eólico é um gráfico que mostra a relação entre a velocidade do vento e a potência elétrica que a turbina eólica pode produzir. Esta curva caracteriza o desempenho de uma turbina em diferentes condições de vento e ajuda a determinar a quantidade de energia que será gerada para cada velocidade específica do vento (Lima et al., 2017).

Os geradores são concebidos para atingir a sua potência máxima a uma determinada velocidade do vento. Esta potência é denominada potência nominal, e a velocidade do vento na qual essa potência é alcançada é chamada de velocidade nominal do vento. É importante destacar que esta velocidade não é padronizada, pois varia de acordo com o fabricante e do tipo da turbina eólica. No entanto, é comum encontrar valores entre 13 e 16 m/s (Castro, 2018). A figura 2.4 apresenta um exemplo de uma curva de potência, que representa a relação entre a potência elétrica e a velocidade do vento, referente a um sistema de conversão de energia eólica com uma potência nominal de 500 kW. Estas características são disponibilizadas pelo fabricante.




Figura 2.4 - Curva de potência da turbina eólica Enercon E40-500 kW (Adaptado de Lima et al., 2017)

Segundo o Castro (2018), curva de potência é definida por três parâmetros principais:

Velocidade de arranque: A velocidade mínima do vento (geralmente entre 4 e 5 m/s) necessária para que as lâminas da turbina comecem a girar e a turbina inicie a geração de energia elétrica.

Velocidade nominal: A velocidade do vento na qual a turbina atinge a sua potência máxima (ou potência nominal). A partir deste ponto, mesmo que o vento aumente, a potência gerada permanece constante.

Velocidade de corte: A velocidade máxima do vento (geralmente entre 25 e 30 m/s) além da qual a turbina eólica é desligada por razões de segurança. Quando a velocidade do vento excede este valor, a produção de potência cai para zero.

## **2.4 Previsão de Produção de Energia Eólica**

A previsão da produção de energia eólica refere-se à estimativa da quantidade de energia elétrica que pode ser gerada a partir do vento em determinado período e local, com base em dados meteorológicos e modelos de previsão (Monteiro et al., 2009). Esta previsão é fundamental para o planejamento eficiente da integração da energia eólica na rede elétrica, de modo a garantir a estabilidade e a fiabilidade do fornecimento de energia, além de contribuir para a regulação do mercado energético.

As investigações sobre a previsão de produção da energia eólica para a geração de energia elétrica através de turbinas eólicas começaram no século XX, particularmente na década de 1980, como mencionado por McCarthy (1997), numa conferência realizada no Texas, EUA. Desde então, centros de investigação, universidades e empresas do setor elétrico têm investido significativamente no desenvolvimento de métodos e ferramentas operacionais mais eficientes para realizar estimativas de produção. Este esforço tem levado a um aumento considerável no número de modelos de previsão disponíveis (Capitão, 2010).

### **2.4.1 Principais Métodos de Previsão do Vento**

Para os operadores de turbinas eólicas ou parques eólicos, é fundamental poder prever com precisão a produção de energia eólica com antecedência. Essa capacidade de previsão abrange um período que varia em minutos, horas até um ou mais dias, e é crucial para garantir uma integração eficaz da energia gerada pelas turbinas à rede elétrica (Manwell et al., 2010).

As previsões de energia eólica são geralmente classificadas em duas categorias: Determinísticas e Probabilísticas. Nesta dissertação, serão apenas analisados os métodos

determinísticos, uma vez que são os mais utilizados na área das energias renováveis. Estes métodos são classificados por:

- Métodos Físicos
- Métodos Estatísticos
- Métodos de Referência - Persistência
- Métodos Híbridos

#### **2.4.1.1 Métodos Físicos**

A previsão do vento com base em modelos físicos é feita através dos modelos de Previsão Numérica do Tempo, que consistem em modelos matemáticos para prever as condições atmosféricas. Estes modelos usam equações que descrevem as forças que influenciam o movimento do vento. A partir do estado atual da atmosfera, estes modelos permitem estimar a evolução de variáveis como temperatura, velocidade do vento, humidade e pressão em pontos definidos numa grelha específica. Além disso, consideram como cada ponto da grelha afetará os seus vizinhos, bem como informações sobre o terreno, como altitude, rugosidade e obstáculos (Castro, 2018).

#### **2.4.1.2 Métodos Estatísticos**

E quanto aos métodos estatísticos, estes são baseados em modelos matemáticos que inicialmente analisam os dados históricos disponíveis. Por vezes, podem incorporar informações provenientes dos modelos NWP. Posteriormente, fazem estimativas para os valores seguintes aos dados analisados, de modo a permitir prever os valores futuros de uma determinada grandeza com base nos dados históricos passados dessa mesma grandeza (Castro, 2018).

Os métodos estatísticos subdividem-se em dois métodos mais utilizados na área de engenharia eletrotécnica: os auto-regressivos ARMA que consistem em modelos lineares, e as redes neurais artificiais, ANN, que consistem em modelos não lineares.

#### **2.4.1.3 Método de Referência**

Este método é empregue como uma referência para avaliar o desempenho de outros métodos de previsão. Considera-se que um sistema de previsão só é relevante se for superior aos métodos de referência. Esses métodos não envolvem a criação de modelos complexos, mas

são baseados em considerações simples. Um dos métodos mais conhecidos é o método da persistência (Capitão, 2010), este método demonstra resultados satisfatórios em previsões com uma hora de antecedência (Castro, 2018).

#### 2.4.1.4 Métodos Híbridos

Os métodos híbridos de previsão de produção de energia eólica combinam os métodos físicos e estatísticos para aumentar a precisão e eficiência das previsões. Esses métodos se destacam pela capacidade de integrar as vantagens de cada técnica, compensar as limitações dos métodos individuais e, assim, fornecer previsões mais precisas, especialmente em ambientes complexos e com dados históricos com características muito atípicas (Lin et al., 2020).

O organograma abaixo apresenta, de forma resumida, a classificação dos principais métodos de previsão de produção de energia eólica. No próximo capítulo, será feita uma análise mais detalhada desses métodos, incluindo as suas versões mais recentes.




Figura 2.5-Classificação dos Principais métodos de Previsão

## 2.5 Horizonte de Previsão do Vento

Diferentes autores apresentam diferentes pontos de vista sobre a classificação da escala do horizonte temporal. Chen & Folly (2018) sugerem uma divisão da escala de tempo para a operação dos sistemas elétricos em quatro categorias distintas, conforme apresentado na tabela abaixo:

Tabela 2.1 - Classificação do horizonte temporal para previsão de energia eólica

| Horizonte Temporal                    | Intervalo                      | Aplicações                                                                                                                                                                                                                   |
|---------------------------------------|--------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <b>Muito Curto Prazo (em minutos)</b> | Poucos segundos até 30 minutos | <ul style="list-style-type: none"> <li>- Compensação do mercado de energia elétrica.</li> <li>- Operações em tempo real da rede elétrica.</li> <li>- Ações regulatórias.</li> </ul>                                          |
| <b>Curto Prazo (em horas)</b>         | 30 minutos até 6 horas         | <ul style="list-style-type: none"> <li>- Planeamento Económico e Pré-Despacho.</li> <li>- Decisão de incremento ou decréscimo de carga.</li> </ul>                                                                           |
| <b>Médio Prazo (em dias)</b>          | 6 horas até 1 dia              | <ul style="list-style-type: none"> <li>- Decisões de ligar ou desligar os aerogeradores.</li> <li>- Segurança operacional no mercado.</li> <li>- Decisões de reserva de contingência.</li> </ul>                             |
| <b>Longo Prazo (em anos)</b>          | Vários dias, até 1 ano ou mais | <ul style="list-style-type: none"> <li>- Planeamento de manutenção.</li> <li>- Gestão de operação.</li> <li>- Decisões de compromisso de unidades.</li> <li>- Estudo de viabilidade para design do parque eólico.</li> </ul> |

A tabela 2.1 descreve os diferentes horizontes temporais utilizados na previsão de produção de energia eólica, segmentando-os em quatro categorias distintas, de acordo com o intervalo de tempo considerado:

O Muito Curto Prazo refere-se a previsões feitas para intervalos de tempo extremamente breves, que variam entre poucos segundos e até 30 minutos. Este horizonte é especialmente importante para operações em tempo real, em que ajustes rápidos na produção ou no consumo de energia são necessários. Os métodos que utilizam este horizonte têm a capacidade de dar resposta quase imediata às variações nas condições do vento.

O Curto Prazo abrange previsões para períodos que variam de 30 minutos até 6 horas. Este intervalo é utilizado para planeamento económico e pré-despacho, ajustar a produção em função das previsões meteorológicas de curto prazo, assegurar a estabilidade e a eficiência no fornecimento de energia.

O Médio Prazo, que cobre intervalos de 6 horas até 1 dia, é importante para o planeamento de operações e a integração da produção eólica com outras fontes de energia, ajustar as previsões de modo a alinhar a oferta com a procura energética e minimizar os possíveis desperdícios ou deficiências de produção.

Por fim, o Longo Prazo refere-se a previsões que se estendem por vários dias, pode alcançar até um ano ou mais. Este horizonte é utilizado para o planeamento estratégico da produção de energia eólica, influenciar decisões sobre a manutenção e implementação de novas

infraestruturas, a gestão de recursos e a coordenação com outras fontes de energia renovável, de modo a garantir um fornecimento estável e sustentável a longo prazo.

Desta feita, a classificação dos métodos de previsão quanto ao horizonte temporal permite uma melhor gestão da produção de energia eólica, assegurar que as previsões sejam ajustadas adequadamente em função das necessidades operacionais e estratégicas, melhorar a eficiência e a fiabilidade do sistema energético.

## 2.6 Casos de Estudos Aplicados

Diversos estudos científicos foram conduzidos por diferentes autores no âmbito da previsão da produção de energia renovável por meio do recurso eólico. Esses estudos abrangem uma variedade de métodos de previsão, desde os convencionais, que se baseiam em modelos físicos e estatísticos, até os mais avançados, que fazem uso de técnicas de inteligência artificial, em particular o aprendizado de máquina. A seguir, apresentaremos um resumo conciso desses trabalhos, destacando suas conclusões e contribuições para o campo da previsão de energia eólica.

Em Al-Yahyai et al. (2010), foi realizado um estudo que ofereceu uma visão geral do uso de dados obtidos no modelo NWP para avaliação de recursos de energia eólica. Este artigo explorou as capacidades dos modelos de NWP e como eles abordaram as limitações associadas às medições do vento.

Com este estudo, concluiu-se que embora os NWP tenham fornecido dados superiores, eram apenas uma aproximação da realidade e apresentavam incertezas, como o viés de velocidade do vento. Os métodos estatísticos, como MOS e filtro de Kalman, foram usadas para corrigir o viés nos dados do modelo. Melhorias na física e dinâmica do modelo, assim como nos algoritmos de assimilação de dados, puderam melhorar os resultados de verificação.

Lange et al. (2001), desenvolveram uma abordagem física para prever a produção de energia eólica com antecedência de até 48 horas. Este método baseou-se em princípios físicos e utilizou dados de entrada de um modelo de NWP. A modelagem da camada limite considerou inicialmente a rugosidade, o terreno e o efeito de esteira. Além disso, foi considerada a variação diária da estratificação térmica da atmosfera para prever a velocidade do vento à altura do cubo da turbina.

No estudo realizado por De Felice et al. (2013), foi utilizado um modelo físico para prever a procura de energia elétrica em Itália, com base em dados de meteorologia a horária ao longo de 14 meses. Ao comparar o método proposto com uma abordagem simples através MAE, os resultados mostraram que o NWP podem melhorar o desempenho das previsões, especialmente nas regiões mais quentes. Os autores concluíram que apesar de ser considerado um método eficaz para a prever as características do vento para produção energia eólica a médio e longo prazo, complexidade computacional do NWP requer recursos computacionais consideráveis.

No estudo conduzido por Firat et al. (2010) foi desenvolvido um modelo estatístico baseado na análise de componentes independentes e no modelo AR para prever a produção da energia eólica. Neste trabalho, foi utilizado como parâmetros de entrada a velocidade do vento ao longo de seis anos de um parque eólico nos Países Baixos. Os mesmos autores concluíram que o modelo proposto pode proporcionar maior precisão em comparação com os métodos de previsão direta para horizontes de 2 a 14 horas à frente.

Durán et al. (2007) realizaram estudo, onde foi criado um modelo AR com variável exógena. Neste estudo foi utilizado a velocidade do vento como parâmetro exógena. Eles realizaram análises comparativas entre modelos persistentes, AR e ARX, para previsões de 6, 12 e 24 horas, considerando diferentes parques eólicos de maneira independente e agregada. Com os resultados obtidos pelo modelo foi possível compararam o erro médio do seu modelo com os modelos de persistência e AR tradicional. Portanto, foi evidenciado melhorias significativas na precisão das previsões.

O estudo conduzido por Gallego et al. (2011) investigou o impacto da velocidade e direção do vento local na dinâmica da produção da energia eólica. Este estudo focou na previsão muito à curto prazo offshore no parque eólico Horns Rev, na Dinamarca. Ao comparar modelos de coeficientes variáveis, a pesquisa destacou a importância de incorporar variáveis locais observadas na modelagem estatística para melhorar a precisão das previsões da produção da energia eólica. Os resultados sublinharam a importância de considerar tanto a velocidade quanto a direção do vento para entender as dinâmicas complexas das séries temporais desses parâmetros para previsão da produção energia eólica. Este estudo ofereceu insights valiosos

para aprimorar a eficiência e confiabilidade dos sistemas de energia eólica por meio de métodos avançados de previsão.

No trabalho realizado por Bilal et al. (2018) foi desenvolvido uma rede neuronal do tipo MLP para prever a produção de energia eólica em quatro parques eólicos no Senegal. Para este estudo, foi utilizado como variável principal de entrada no modelo a velocidade do vento, porém foram avaliadas também várias combinações de outras variáveis, como a direção do vento, a temperatura, a humidade e a radiação solar. Os resultados indicaram que, além da velocidade do vento, a temperatura do ar teve o maior impacto na melhoria da precisão do modelo. Para identificar a configuração ideal da rede MLP, os pesquisadores aplicaram o algoritmo de retropropagação de Levenberg-Marquardt como técnica de treino, utilizando a função de ativação sigmoide. Eles descobriram que a rede MLP, composta por três camadas ocultas com 5, 7 e 8 neurônios em cada camada, alcançou o menor NMSE.

No trabalho feito por Sideratos & Hatziargyriou (2007), foi realizado um estudo onde aplicando uma combinação de redes neurais e técnicas de lógica Fuzzy para estimar com precisão a produção de um parque eólico. Inicialmente, um mapa auto-organizado foi utilizado para classificar os dados de entrada em três categorias, com base na magnitude da velocidade do vento na hora da previsão e na hora seguinte. Cada categoria teve uma rede RBFNN distinta que forneceu uma previsão preliminar. Essa previsão foi então comparada com os resultados de duas outras redes RBFNN, treinadas para prever o valor teórico da energia eólica a partir das previsões NWP e da curva de potência das turbinas em relação à velocidade do vento. A comparação utilizou um modelo Fuzzy para gerar um indicador de qualidade das previsões de velocidade do vento, correlacionando-as com a direção do vento. Este indicador foi então utilizado por uma rede RBF para fornecer a previsão final. Os resultados da aplicação deste método a um parque eólico offshore real demonstraram a sua eficácia no planeamento operacional, com previsões válidas para um horizonte de 1 a 48 horas.

No estudo realizado por Xu & Mao (2016) foi aplicado uma rede neuronal ENN para estudar a previsão de produção de uma única turbina eólica de 15 kW em um parque eólico localizado no oeste da China. Para este estudo, foram utilizados variáveis como velocidade do vento, direção do vento, humidade e temperatura como entrada, com este estudo, foi possível alcançar resultados satisfatórios.

Em Chang (2013), foi desenvolvido um modelo estatístico baseado em rede neuronal de retropropagação BPNN para previsão da produção de energia eólica num horizonte de 10 minutos. No estudo feito foram utilizados os dados históricos da produção de energia de uma turbina em Taiwan para validar a eficácia do método, portanto, este estudo revelou que a rede neuronal proposta conseguiu prever a produção de energia eólica com um erro médio absoluto de 0,278%.

Em Hong & Rioflorido (2019) foi proposto um modelo híbrido de previsão de energia eólica projetado para prever a produção de energia eólica num horizonte 24 horas, onde foi utilizado a rede neuronal CNN. Neste estudo, as operações da CNN incluíram técnicas de convolução, pooling e kernel para extrair características de entrada. Essas características extraídas foram posteriormente alimentadas em uma rede RBFNN que implementou uma função Gaussiana dupla como sua função de ativação. Além disso, os autores utilizaram um otimizador para melhorar tanto os componentes CNN quanto RBFNN. O estudo utilizou um ano de dados históricos de produção de energia de um parque eólico localizado em Taiwan. Os resultados demonstraram que sua abordagem híbrida superou vários modelos de referência, incluindo rede MLP com Algoritmo Genético (MFNN-GA), RBFNN-GA, RBFNN-DGF, CNN-MFNN e CNN-RBFNN. Além disso, eles descobriram que a integração da DGF na RBFNN produziu resultados superiores em comparação com RBFNN tradicionais que utilizam apenas funções Gaussianas.

No trabalho realizado por Lima et al. (2017), foi desenvolvido um modelo que combina métodos físicos e estatísticos. Os dados iniciais utilizados neste estudo foram as previsões atmosféricas em escala global fornecidas pelo sistema global de previsões. E para refinar as previsões, os autores recorreram ao modelo brasileiro de previsão numérica do tempo, que incorpora considerações físicas do terreno, como cobertura vegetal e características do solo. Posteriormente, aplicaram um filtro de correção de erros sistemáticos capaz de aprender o comportamento dinâmico dos dados de vento, o que reduziu de forma significativa os vieses das previsões.

Após corrigir os vieses, utilizaram dois métodos principais para a previsão da energia eólica: a curva de potência do fabricante e equações de regressão baseadas em medições de vento e dados de energia gerados pelos sistemas SCADA. Para gerar as regressões, foi levado

em consideração dados observados ao longo de um ano e utilizado quatro tipos de equações: linear, quadrática com considerações de saídas de potência anteriores e cúbica. Comparações com índices estatísticos como RMSE revelaram que a regressão cúbica apresentou os melhores resultados.

Nesta pesquisa, foi confirmado também que fatores como densidade do ar, efeito de esteira e orografia podem influenciar significativamente na produção de energia. O filtro de Kalman foi reaplicado com o objetivo de corrigir os erros sistemáticos presentes no modelo de conversão. Concluiu-se que o uso do filtro de Kalman reduziu os valores de RMSE e aumentou os valores do coeficiente de correlação de anomalia e do coeficiente de Nash-Sutcliffe, o que resultou na melhoria significativa na previsão.

De Giorgi et al. (2011) realizaram um estudo em que desenvolveram um modelo híbrido, ao combinarem a rede MLP e Elman. Os autores utilizaram uma combinação de dados históricos medidos online e dados históricos provenientes do modelo NWP para melhorar significativamente as previsões de energia eólica em comparação com o sistema de previsão I, que se baseava apenas na série temporal histórica de potência eólica medida. A análise de sensibilidade realizada com os sistemas de previsão II a VI evidenciou que, além da clara relevância da velocidade do vento prevista, os parâmetros NWP como pressão e temperatura também trazem benefícios significativos ao modelo de previsão. Sistemas de previsão que incluíam umidade relativa entre suas variáveis (III, IV e VI) apresentaram desempenho inferior ao sistema V, que se baseava em velocidades de vento, pressões e temperaturas provenientes das NWP.

O sistema de previsão VIII, uma combinação de duas redes neurais (Elman e MLP), foi destacado como o mais eficaz, porque proporcionou uma melhor qualidade nas previsões e sendo particularmente adequado para aplicações online devido à sua capacidade de treino periódico com novos dados, adaptando-se às variações dinâmicas do processo. No entanto, os autores concluíram que esse sistema é mais complexo e precisa de mais operações de treino para gerar previsões precisas, quando comparado aos métodos I a VI, que garantem um tempo computacional mais curto.

Em Zhao et al. (2012) realizaram um estudo, onde aplicado o filtro de Kalman para reduzir os erros sistemáticos da velocidade do vento gerados a partir do modelo NWP. O

modelo empregou a direção do vento, temperatura e humidade como variáveis de entrada numa rede MLP para prever a energia eólica do dia seguinte. Os resultados indicaram que, ao filtrar a velocidade bruta e utilizar a MLP, foi possível reduzir o NRMSE de 17,81% para 16,47%.

## MÉTODOS DE PREVISÃO

Neste capítulo, serão abordados os principais métodos de previsão de energia eólica, suas classificações com ênfase nos métodos físicos, estatísticos, de persistência e híbridos, todos baseados em modelos determinísticos. Será realizada uma análise detalhada dos principais fatores que impactam a precisão das previsões. Por fim, será realizada uma análise comparativa entre os métodos descritos, bem como identificar as principais vantagens de cada um em relação aos demais, suas limitações e suas aplicações em cenários específicos de previsão de produção de energia elétrica por meio eólico.

### 3.1 Previsão da Potência Eólica

Após realizar o levantamento do estado da arte, constatou-se que para garantir a produção de energia elétrica proveniente do gerador ou parque eólico e posteriormente sua injeção na rede elétrica em qualquer momento, é essencial manter o equilíbrio entre o consumo e a produção de energia elétrica. Caso contrário, podem ocorrer perturbações na qualidade ou no fornecimento de energia (Castro, 2018). Nesse contexto, a previsão precisa da produção desempenha um papel crucial na otimização da eficiência e fiabilidade dos parques eólicos. Assim, ao prever com precisão os padrões do vento e consequentemente a potência elétrica que o parque eólico irá produzir, as empresas de energia podem antecipar as flutuações na produção de energia elétrica e tomar decisões coerentes sobre geração, transmissão e distribuição de energia e evitar desta maneira penalizações futuras. Portanto, a previsão do potencial eólico ajuda a:

- ▲ **Maximizar a Produção de Energia Elétrica:** As previsões do vento permitem aos operadores ajustar a posição e operação dos aerogeradores para capturar a máxima potência eólica disponível, ou seja, ao alinhar a direção e velocidade dos

aerogeradores com os padrões de vento previstos, a produção de energia será otimizada.

- ▲ **Integração na Rede:** Auxiliam os operadores de rede a equilibrar a procura e a oferta de energia elétrica. Ao antecipar as mudanças na produção de energia eólica, os operadores de rede podem programar a ativação de fontes de energia de reserva ou ajustar a produção de outras fontes geradoras para manter a estabilidade da rede.
- ▲ **Negociação de Energia:** Permitem às empresas de energia participar de forma mais eficaz nos mercados de energia. Ao prever a produção futura de energia eólica, as empresas podem comprar ou vender contratos de energia a preços vantajosos, maximizar a receita e minimizar os custos.
- ▲ **Planeamento de Manutenção:** Ajudam no agendamento das atividades de manutenção para os aerogeradores. Ao prever períodos de vento fraco ou tempo de paralisação, as equipas de manutenção podem realizar inspeções programadas, reparos ou substituições de componentes sem interromper a produção de energia (Principalmente em offshore onde o custo de manutenção é elevado).
- ▲ **Gestão de Riscos:** por fim, as previsões precisas da energia eólica auxiliam na avaliação e gestão dos riscos operacionais associados à produção de energia eólica. Ao antecipar eventos climáticos extremos ou variabilidade do vento, as empresas de energia podem implementar estratégias de mitigação para minimizar o impacto na produção de energia e na infraestrutura.

## 3.2 Classificação da Previsão de Energia Eólica

Com base na revisão bibliográfica realizada, teoricamente, a previsão de energia eólica pode ser classificada de acordo com os horizontes temporais e a metodologia aplicada. Tal como descrito no capítulo anterior, as escalas de tempo de previsão podem ser divididas em várias categorias. A começar pelo muito curto prazo, para o qual as previsões geralmente variam de alguns segundos até 30 minutos, seguido pelo curto prazo, que abrange um intervalo de 30 minutos até 6 horas em seguida, o médio prazo, que se estende de 6 horas a 1 dia, e por fim, os cenários de longo prazo, que englobam intervalos de vários dias até um ou mais anos.

Portanto, cada escala de tempo é útil para determinadas aplicações. Por exemplo, para o horizonte de muito curto prazo à curto prazo, podem ser úteis para auxiliar no controlo

operacional de turbinas eólicas ou parques eólicos. Já para o horizonte de médio e longo prazo, podem ou são úteis para o planejamento da implementação de outros parques ou estações de energia na rede (Hanifi et al., 2020).

Por outro lado, os métodos de previsão têm se beneficiado significativamente do avanço das ferramentas de computação de alto desempenho, e este avanço tem possibilitado o estabelecimento de métodos computacionais cada vez mais avançados. E como já mencionado, quanto às metodologias, os métodos de previsão da energia eólica podem ser classificados em:

- ▲ Modelos Físicos (geralmente empregues para horizontes de médio e longo prazo).
- ▲ Modelos Estatísticos (para horizontes de muito e curto prazo).
- ▲ Modelos Híbridos (para ambos os casos)
- ▲ E de Referência - Persistência

### **3.2.1 Métodos Físicos**

Para prever a produção de energia eólica com base em modelos físicos, geralmente utiliza-se o método de previsão numérica do tempo. Os modelos físicos estimam as características futuras do vento tendo em conta fatores como o terreno, os obstáculos, a pressão e a temperatura (Lei et al., 2009). Neste contexto, estes modelos incorporam considerações físicas detalhadas para realizarem previsões do vento.

#### **3.2.1.1 Método NWP**

Entre os modelos físicos utilizados para previsão da produção da energia eólica, o método de Previsão Numérica de Tempo se destaca como uma abordagem amplamente empregada. Este método de previsão utiliza dados atmosféricos em tempo real, como a velocidade e direção do vento, pressão atmosférica e humidade, para realizar previsões detalhadas e precisas do vento. O modelo NWP é particularmente eficaz na produção de resultados precisos para previsões de médio e longo prazo (Lei et al., 2009).

E para realizar previsões, normalmente o NWP o modelo faz uma divisão do planeta em diversas camadas verticais, que representam os níveis da atmosfera, por conseguinte divide a superfície do planeta em grelhas horizontais separadas por linhas semelhantes a longitude e latitude (Castro, 2018). Esta representação indica que a atmosfera será amostrada por cerca de um milhão ou mais de cubos individuais.

E em seguida, esses dados são inseridos nos modelos computacionais, onde é feita a subdivisão da atmosfera em grelhas tridimensionais, conforme ilustra a figura 3.1 e calculam

a evolução dessas variáveis atmosféricas ao longo do tempo, ou seja, em cada ponto da grade, as componentes do vento, como, a velocidade, temperatura, pressão e humidade são calculadas. E para realizar a previsão, normalmente o modelo usa um passo de 10 minutos durante a simulação, para fazer previsões que podem variar de 5 a 10 dias (Capitão, 2010).




Figura 3.1: Cubos tridimensionais da atmosfera utilizados pelos modelos NWP (Al-Yahyai et al., 2010)

Assim, o valor previsto representa a média da área da caixa de grade conforme mostrado na figura 3.2:




Figura 3.2- Caixa de Grade (Al-Yahyai et al., 2010)

A distância entre os pontos adjacentes de uma grade é essencial para determinar a precisão de um modelo na resolução horizontal. Modelos com maior resolução, ou seja, com pontos de grade mais próximos, tendem a oferecer resultados mais precisos em comparação com modelos de resolução mais baixa. No entanto, esses modelos de alta resolução exigem recursos computacionais mais potentes. Como mencionado por Al-Yahyai et al. (2010), reduzir a resolução horizontal pela metade aumenta significativamente o número de pontos na grade, o que implica maior capacidade de processamento.

A resolução do modelo também influencia diretamente a precisão da representação topográfica do terreno. Modelos de alta resolução dependem da qualidade dos dados

topográficos disponíveis. Se os dados forem de baixa qualidade, o modelo poderá falhar na representação detalhada de características geográficas importantes, como montanhas e vales, afetando assim a fidelidade das previsões.

Apesar dos avanços na capacidade dos supercomputadores, as previsões dos modelos físicos, como os NWP, ainda podem ser imprecisas devido a erros sistemáticos nos dados brutos. Para corrigir esses erros, é comum o uso de técnicas estatísticas como o MOS, que ajustam as saídas dos modelos com base em observações históricas e dados reais.

#### **3.2.1.2 Estatística de Saída do Modelo NWP - (MOS)**

Segundo Lazić et al. (2014), o método MOS utiliza estatísticas adaptativas baseadas em medições em tempo real da produção de energia eólica para corrigir desvios recentes nas previsões. Os dados de entrada para o MOS incluem dados históricos dos aerogeradores e previsões de modelos NWP.

Inicialmente, o MOS foi criado para melhorar previsões meteorológicas de variáveis de superfície com base em modelos NWP. O método segue duas etapas: primeiro, são estabelecidas relações empíricas entre as variáveis meteorológicas observadas e os preditores em larga escala gerados pelo modelo. Em seguida, essas relações, muitas vezes expressas por equações de regressão, são aplicadas à saída do modelo meteorológico, melhorando a precisão das previsões em larga escala e de superfície.

Assim, o MOS corrige e aperfeiçoa a previsão inicial dos modelos físicos. Ele utiliza dados históricos para ajustar as previsões com base em padrões observados, aprimorando a precisão das previsões, especialmente nas variáveis de superfície, onde os modelos atmosféricos tendem a ser menos precisos.

#### **3.2.1.3 Etapas de Previsão de Produção de Energia Eólica do Método Físico**

Para prever a produção de energia eólica, os métodos físicos seguem dois passos principais: a redução de escala e a conversão para potência (Monteiro et al., 2009), conforme ilustrado na figura 3.3.




Figura 3.3 - Principais Etapas do Método Físico (Monteiro et al., 2009)

Na primeira etapa, a velocidade e a direção do vento são ajustadas para a altura do cubo da turbina. As previsões de velocidade e direção do vento fornecidas pelo modelo são refinadas utilizando vetores de vento, pressão atmosférica e temperatura para uma determinada região (em uma grade específica). Esse processo também incorpora dados SCADA, características do parque eólico e do terreno. O refinamento leva em consideração a rugosidade local, a orografia e a estabilidade atmosférica, de maneira a modelar o perfil local do vento (Monteiro et al., 2009).

Na segunda etapa, a velocidade do vento ajustada é convertida em potência, este processo consegue-se por meio da curva de potência da turbina eólica fornecida pelo fabricante. Alternativamente, é possível estimar a curva de potência com base nas previsões de velocidade e direção do vento e na potência medida, uma técnica que oferece vantagens práticas (Monteiro et al., 2009).

### 3.2.2 Modelos Estatísticos

A segunda categoria de modelos utilizados para a previsão de produção de energia eólica é o modelo estatístico. Ao contrário dos modelos físicos, que descrevem os processos físicos envolvidos na conversão de energia eólica, os modelos estatísticos têm como foco a identificação de relações entre variáveis de entrada relevantes, como velocidade e direção do vento,

temperatura, etc., e a geração de energia. Assim, esses modelos utilizam dados históricos para estimar a produção de energia elétrica por meio eólico com base em correlações estatísticas (Aggarwal et al., 2013).

Esses modelos são desenvolvidos com base aos dados históricos frequentemente provenientes de modelos NWP, que incluem variáveis como velocidade e direção do vento, temperatura, etc. Além disso, são incorporados dados SCADA, que abrangem informações sobre potência produzida, velocidade e direção do vento e outros parâmetros. A integração dessas informações possibilita uma previsão mais precisa da geração de energia eólica, conforme ilustrado na figura 3.4 (Monteiro et al., 2009).




Figura 3.4- Etapas do Método Estatístico (Monteiro et al., 2009)

O diagrama acima, descreve as principais etapas que um modelo estatístico para realizar a previsão. A estrutura normalmente contém duas entradas principais: uma relacionada a dados históricos meteorológicos e outra a dados históricos de produção de energia eólica. Esses dados são fundamentais para alimentar o processo de previsão, já que as condições meteorológicas (como velocidade do vento, densidade do ar, etc.) impactam diretamente a capacidade de geração de energia em sistemas eólicos.

Após o recebimento dessas entradas, segue-se para o estágio intermediário, onde ocorre processo de modelagem, ou seja, o modelo estatístico recebe os dados históricos e os processa para gerar previsões. Por fim, ocorre a última fase, onde são apresentados os resultados da previsão.

Portanto, no bloco estatístico, primeiro ocorre a fase de treino, na qual os dados históricos são utilizados como dados de treino. Durante esta etapa, este bloco ajusta as variáveis internas do modelo para reduzir o erro entre os dados históricos reais e os dados reproduzidos pelo modelo, explicando assim os dados históricos disponíveis (Castro, 2018).

Embora esse modelo seja mais simples de construir e menos dispendioso, sendo utilizado principalmente para prever produção de energia eólica em horizontes de curto e muito curto prazo, sua precisão tende a diminuir à medida que o horizonte de previsão se estende. Isso ocorre devido ao aumento do erro de previsão à medida que o tempo estimado para a ocorrência do vento aumenta.

Os métodos de previsão estatística podem ser divididos em duas categorias principais: modelos ARMA, que consistem em modelos lineares baseados em séries temporais, modelos ANN, que são modelos não lineares baseados em Inteligência Artificial ou aprendizagem das máquinas (ML) (Arslan Tuncar et al., 2024).

### 3.2.2.1 Método ARMA

Os métodos ARMA representam uma ferramenta bastante útil e poderosa para descrever a dinâmica de uma série temporal individual. Estes modelos, propostos por Box e Jenkins na década de 1950, têm como objetivo principal aplicar dados históricos provenientes dos modelos NWP e dados de SCADA para desenvolver um modelo matemático capaz de descrever séries temporais e prever o valor futuro de uma variável. São utilizados não só para o desenvolvimento do modelo em si, mas também para estimar os parâmetros do modelo e verificar a sua capacidade de simulação (Hanifi et al., 2020).

Para compreender o modelo ARMA, é fundamental perceber que este combina duas componentes: a autorregressiva (AR) e a de média móvel (MA), que captam padrões de autocorrelação e variações de curto prazo (Arslan Tuncar et al., 2024; Castro, 2018). No entanto, antes de abordar este modelo baseado em séries temporais, é essencial compreender o que são os processos AR e MA.

Assim, a componente AR do modelo baseia-se na ideia de que os valores futuros de uma série temporal dependem linearmente dos seus próprios valores passados. A ordem do componente AR ( $p$ ) indica quantos valores passados são considerados na previsão do próximo valor (Castro, 2018). Deste modo, um processo AR de ordem  $p$ ,  $AR(p)$ , é definido por:

$$Y_t = c + \varepsilon_t + \sum_{i=1}^p \varphi_i \times Y_{t-i} \quad (3.1)$$

Onde:  $Y_t$  representa a série temporal que se pretende descrever no instante  $t$ ,  $c$  a constante do modelo atribuída de maneira aleatória,  $\varepsilon_t$  o ruído branco (em um termo de erro, variável aleatório),  $\varphi_i$  os parâmetros AR do modelo (números reais),  $Y_{t-i}$  os valores passados utilizados na série para prever os próximos valores e  $p$  ordem do processo auto-regressivo.

Neste contexto, a componente AR do modelo ARMA é baseada na ideia de regressão da variável em relação aos seus próprios valores passados. Isso implica que o valor atual da variável (valor no momento  $t$ ) é modelado como uma combinação linear de seus valores históricos, com coeficientes específicos atribuídos a cada valor passado (valores nos momentos  $t-1$ ,  $t-2$ ,  $t-3$ , e assim por diante). Essa abordagem permite capturar padrões temporais e tendências na série temporal, fornecer uma base para previsões e análises futuras com base nos dados históricos disponíveis (Castro, 2018; Hanifi et al., 2020).

E quanto ao componente MA, ela considera a média dos erros anteriores como um fator determinante na previsão dos valores futuros. De igual modo, a ordem da componente MA ( $q$ ) indica quantos erros passados são incluídos na média móvel (Castro, 2018). No entanto, um processo de média móvel de ordem  $q$ , MA ( $q$ ), caracteriza-se por:

$$Y_t = \mu + \varepsilon_t + \sum_{i=1}^q \theta_i \times \varepsilon_{t-i} \quad (3.2)$$

Onde:  $\mu$  representa a constante do modelo (normalmente tida como nula, ou valor esperado),  $\theta_i$  os parâmetros da média móvel (números reais),  $q$  ordem do processo de média móvel, e  $\varepsilon_{t-i}$  a quantidade dos erros passados que são considerados na série temporal.

Assim, de acordo com Castro (2018), o método ARMA é um processo autorregressivo de ordem  $p$  e de média móvel de ordem  $q$ , denominado ARMA( $p,q$ ). Em outras palavras, este método incorpora termos de média móvel de ordem  $q$  e um processo autorregressivo de ordem  $p$ , conforme expresso abaixo:

$$Y_t = c + \varepsilon_t + \mu + \sum_{i=1}^p \varphi_i \times Y_{t-i} + \sum_{i=1}^q \theta_i \times \varepsilon_{t-i} \quad (3.3)$$

Utilizando o operador de atraso  $L$  e considerando o  $\mu$  nulo, é possível escrever expressão matemática da seguinte forma:

$$\left(1 - \sum_{i=1}^p \varphi_i L^i\right) Y_t = c + \left(1 + \sum_{i=1}^q \theta_i L^i\right) \varepsilon_t \quad (3.4)$$

Um processo ARMA normalmente é considerado como um modelo estacionário, isso acontece porque tanto o seu valor esperado quanto a sua auto-covariância permanecem constantes ao longo do tempo. Por outro lado, para séries temporais que exibem uma tendência (não estacionária), recomenda-se o uso de um processo ARIMA ( $p,d,q$ ). Este processo inclui uma etapa de integração dos últimos  $d$  valores da série, o que o torna uma generalização do processo ARMA (Castro, 2018). A representação de um processo ARIMA ( $p,d,q$ ) é a seguinte:

$$\left(1 - \sum_{i=1}^p \varphi_i L^i\right) (1 - L)^d Y_t = c + \left(1 + \sum_{i=1}^q \theta_i L^i\right) \varepsilon_t \quad (3.5)$$

Onde:  $d$  representa a ordem do processo integrado e  $L$  o operador de atraso.

Assim, os modelos ARIMA representam uma metodologia de análise estatística que utiliza valores anteriores de séries temporais para fazer previsões. São ferramentas poderosas para analisar estruturas lineares em dados de séries temporais e destacam-se pela capacidade de modelar tendências e sazonalidade em dados não estacionários. No entanto, podem apresentar limitações na captura das características complexas e não lineares de processos naturais, como a velocidade do vento, temperatura e densidade do ar. A sua sensibilidade ao ruído e a incapacidade de reagir rapidamente a eventos inesperados podem colocar desafios específicos na previsão de energia eólica (Arslan Tuncar et al., 2024).

#### 3.2.2.1.1 Metodologia de Previsão

Para que os métodos ARMA efetuem a previsão dos próximos valores de uma série temporal, apenas a própria série temporal é necessária como entrada. Desta feita, a previsão é realizada em três passos, conforme ilustrado na figura 3.5:




Figura 3.5 - Metodologia de previsão usando o método ARMA

Conforme pode ser verificado, a metodologia de previsão do ARMA inicia-se com a definição do modelo, que envolve a escolha do número de parâmetros. Em seguida, avança-se para a fase de treino do modelo. Finalmente, na terceira etapa, realiza-se a previsão dos valores futuros da série temporal. Contudo, esta é a metodologia base empregue para efetuar previsões com os métodos ARMA. No entanto, podem surgir ajustes nesta metodologia devido a

diferentes aplicações e ao uso de diferentes softwares para implementar esses métodos, com o objetivo de otimizar o desempenho dos resultados da previsão.

Vale destacar que os modelos estatísticos lineares são caracterizados por sua simplicidade e confiabilidade (Gallego et al., 2011). Neste contexto o método ARMA é um modelo considerado simples de formular e pode ser facilmente aplicado para prever a produção de energia eólica num horizonte temporal de curto prazo. No entanto, podem ser menos precisos ou apresentar desempenhos inadequados, especialmente quando as séries temporais não apresentam características estacionárias (Castro, 2018). De forma resumida, a tabela abaixo ilustra dois modelos baseados em séries temporais, o ARIMA e a sua extensão ARX:

Tabela 3.1 - Métodos de previsão de produção de energia eólica em séries temporais

| Referências            | Método                                     | Descrição                                                                                                                                                                                                                         | Vantagens                                                                                                                                                                                                                                                             | Desvantagens                                                                                                                                                                                                                                                                                              |
|------------------------|--------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| (Durán et al., 2007)   | Autorregressivo com variável exógena (ARX) | É uma técnica de modelagem matemática utilizada para representar sistemas dinâmicos. combina a abordagem autorregressiva (AR) com a inclusão de variáveis exógenas (inputs externos) para prever o comportamento de um parâmetro. | O modelo ARX é relativamente simples de implementar e computacionalmente eficiente, tornando-o adequado para aplicações em tempo real, inclui variáveis exógenas que o faz capturar melhor as dinâmicas do sistema em comparação com modelos autoregressivos simples. | O modelo ARX pode ser sensível a ruídos nos dados de entrada, o que pode afetar a precisão das previsões. Requer dados de entrada e saída de alta qualidade para obter bons resultados. É linear por natureza e pode não capturar adequadamente comportamentos não-lineares complexos em alguns sistemas. |
| (Gallego et al., 2011) | Autorregressivo ARIMA                      | É uma técnica estatística utilizada para modelar e prever séries temporais. Baseia-se na ideia de que os valores passados da série podem ser utilizados para prever os valores futuros.                                           | Simplicidade na implementação e baixo custo computacional. E é eficaz na captura de padrões lineares em séries temporais, o que pode ser útil para previsões de curto prazo.                                                                                          | Limitações na Captura de Não-Linearidades, sensibilidade a ruídos e menor precisão em comparação com métodos que utilizam variáveis exógenas,                                                                                                                                                             |

Vale destacar que o modelo ARX proposto pelo Durán et al. (2007) é uma extensão do modelo ARIMA que inclui variáveis exógenas, ou seja, variáveis externas ao sistema que

podem influenciar o comportamento da série temporal em análise. No modelo ARX, a previsão da variável dependente é feita com base em seus próprios valores passados (componentes autorregressivos) e nos valores presentes e passados das variáveis exógenas.

### **3.2.2.2 Método ANN ou ML**

As redes neurais artificiais ou aprendizagem de máquinas são amplamente aplicadas na previsão de energia eólica devido à sua capacidade de identificar relações não lineares entre as características de entrada e os dados de saída (Hanifi et al., 2020). As ANN representam um tipo de inteligência artificial projetada para imitar as redes neurais biológicas do cérebro humano e dotá-las com a capacidade de prever parâmetros e identificar padrões. As componentes principais de uma rede neuronal artificial incluem os neurónios artificiais, distribuídos pelas várias camadas da rede, interligados através de sinapses, com cada ligação associada a um fator de peso específico (Rodríguez et al., 2020).

Castro (2018) afirma que, estas estruturas permitem simular processos semelhantes ao pensamento humano, adaptar-se a problemas complexos e aprender com a experiência, sendo por isso designadas por aprendizagem de máquinas. Podem ser categorizadas em redes dinâmicas e estáticas. Nas redes estáticas, a saída de cada unidade depende apenas do valor atual das entradas, enquanto nas redes dinâmicas, as unidades são regidas por equações diferenciais, o que lhe confere uma forma de memória.

Relativamente aos pesos das ligações, estes são ajustados através de um processo de aprendizagem, ou treino, que pode ser supervisionado ou não supervisionado. No processo de aprendizagem supervisionada, a rede é exposta a pares de entradas e saídas desejadas, e os pesos dos neurónios do modelo são ajustados de forma iterativa para minimizar uma função de erro definida e produzir resultados precisos. No processo de aprendizagem não supervisionada, a rede recebe apenas os valores das entradas e é treinada para identificar diferentes classes de dados (Castro, 2018).

De acordo com (Ribeiro et al., 2022), as ANN são técnicas estatísticas que utilizam a inteligência artificial para realizar previsões, em vez de se basearem simplesmente em funções matemáticas. As redes neurais utilizam conexões ponderadas dentro da rede, ajustadas com valores provenientes de dados históricos. Estes dados históricos servem como entrada para a rede neuronal, enquanto o valor previsto da variável constitui a saída, e as camadas ocultas contêm as funções de ativação escolhidas, responsáveis pelo processamento dos dados de entrada.

No entanto, o desempenho da ANN depende de diversos fatores, incluindo o pré-processamento de dados, a estrutura dos dados, o método de aprendizado aplicado, as conexões entre os dados de entrada e saída, entre outros. De acordo a revisão bibliográfica, existem vários algoritmos de redes neuronais artificiais, a destacar: MLP, WNN, BPNN, RBFNN, ENN, LSTM, CNN, entre outros.


Neste contexto, projetar um modelo de ANN envolve duas etapas principais: primeiro, a seleção da estrutura adequada da rede e, em seguida, a especificação da direção da informação transmitida. Existem duas topologias principais: *feedforward*, onde os dados passam em uma única direção das camadas de entrada para as de saída, e recorrentes (recursivo), onde os dados podem ser transmitidos em ambas as direções. A segunda etapa é escolher o algoritmo de aprendizado correto, que pode ser supervisionado, não supervisionado ou por reforço. Portanto, para a previsão da velocidade do vento e da produção de energia eólica, normalmente utilizam-se as redes *feedforward*, pois caracterizam-se por apresentar uma topologia sem ciclos direcionados, ou seja, os dados fluem numa única direção, desde a entrada até à saída, sem formar ciclos ou laços (Hanifi et al., 2020).

É importante salientar que existem mais de 50 tipos de redes neuronais artificiais. Deste modo, a Tabela 3.2 apresenta uma visão geral de alguns dos algoritmos desenvolvidos para a previsão da produção de energia eólica:

Tabela 3.2 - Diferentes algoritmos de previsão de energia eólica ANN

| Referências            | Algoritmo ANN                                                  | Descrição                                                                                                                                                                                              | Vantagem                                                                                                  | Desvantagem                                                                                         |
|------------------------|----------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------|
| (Bilal et al., 2018)   | Perceptrão Multicamada - MLP                                   | Rede neural artificial composta por várias camadas de neurônios, pode incluir uma ou mais camadas ocultas. Essas camadas ocultas permitem que o MLP aprenda padrões complexos e não lineares nos dados | Capacidade de aprendizagem não linear, flexibilidade e capacidade em lidar com grande quantidade de dados | Treino demorado, para ter bons resultados requer grandes conjuntos de dados e risco de overfitting. |
| (Y. Zhao et al., 2016) | Máquina de Aprendizado Extremo Bidirecional - Bidirecional ELM | É uma extensão do algoritmo ELM tradicional, projetada para melhorar a capacidade de aprendizado e a eficiência de redes neuronais artificiais utiliza duas direções de aprendizado.                   | Treino rápido, reduz o risco de overfitting e eficiência computacional.                                   | Complexidade de operação e limitações em aplicações específicas                                     |

|                                     |                                                 |                                                                                                                                                                                                                                                                     |                                                                                                                               |                                                                                                                                                                                   |
|-------------------------------------|-------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| (Castro, 2018; Hanifi et al., 2020) | Rede neuronal de retro propagação (BPNN)        | É uma rede neuronal feedforward composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. O algoritmo de retropropagação é utilizado para ajustar os pesos das conexões entre os neurônios.                                            | Eficiência no treino, flexibilidade e simplicidade na aplicação                                                               | O processo de treino pode ser demorado, especialmente para redes profundas com muitas camadas ocultas.                                                                            |
| (De Giorgi et al., 2011)            | Rede neuronal de Elman - ENN                    | Rede neuronal recorrente proposta por Jeffrey Elman em 1990. Adiciona uma camada de contexto como um operador de atraso de um passo com base na camada oculta. Isso permite que a rede tenha memória.                                                               | Possui memória temporal o que o faz ter a capacidade de armazenar informações de estados.                                     | O treino pode ser mais complexo e demorado em comparação com redes neurais feedforward devido à necessidade de ajustar os pesos da camada de contexto                             |
| (J. Zhang et al., 2019)             | memória de longo curto prazo (LSTM),            | Rede neuronal recorrente avançada projetada para modelar dependências de longo prazo em dados sequenciais                                                                                                                                                           | Capacidade de capturar dependências de longo prazo, versatilidade e melhora de desempenho dos dados                           | Complexidade computacional e dificuldade em ajustar Hiperparâmetros                                                                                                               |
| (Sideratos & Hatzigiorgiou, 2007)   | Redes neuronal de Função de Base Radial - RBFNN | Rede que utiliza funções de base radial como funções de ativação. Utilizadas para tarefas de classificação, regressão e previsão de séries temporais.                                                                                                               | Treino rápido têm uma forte capacidade de aproximação de funções, o que as torna eficazes para previsão.                      | Podem enfrentar dificuldades de escalabilidade quando aplicadas a problemas com grandes conjuntos de dados, devido ao aumento do número de neurônios necessários na camada oculta |
| (Jyothi & Rao, 2016)                | Rede Neuronal Adaptativa - Wavelet NN (AWNn)    | Rede neuronal que utiliza funções <i>wavelet</i> como funções de ativação nos neurônios da camada oculta. As <i>wavelets</i> permitem a decomposição dos dados em diferentes escalas e ajusta os parâmetros das funções <i>wavelet</i> durante o treino para melhor | Capacidade de decompor os dados em várias escalas permite uma análise detalhada e precisa de padrões complexos <sup>2</sup> . | treino de uma AWNN pode ser computacionalmente intensivo, especialmente para grandes conjuntos de dados, fazendo que ela tenha uma capacidade computacional complexa              |



No entanto, após a análise de alguns trabalhos relacionados e dos principais modelos (algoritmos) de redes neurais artificiais aplicados, constatou-se que os tipos mais amplamente utilizados para a previsão da produção de energia eólica são as redes neurais do tipo MLP, redes neurais de função de Base Radial e a rede neuronal recorrente Elman. Esta preferência deve-se às suas capacidades de capturar padrões complexos nos dados, lidar com não-linearidades e prever séries temporais com precisão. Estes modelos destacam-se pela sua flexibilidade na modelação de diferentes tipos de dados de entrada, como a velocidade e direção do vento, a temperatura e a pressão atmosférica, além da sua eficácia comprovada em diversos estudos de caso e contextos geográficos variados. A seguir, serão abordados estes modelos.

### 3.2.2.2.1 Estrutura da Rede - MLP

Perceptrão Multicamadas é um tipo clássico de rede neuronal artificial, composta por múltiplas camadas de nós interconectados. Esta rede *feedforward* estática utiliza aprendizagem supervisionada e é frequentemente aplicada na previsão da produção de energia eólica. A Figura 3.6 ilustra a estrutura típica de uma rede MLP, onde as unidades da rede são representadas por círculos brancos e as ligações entre elas por segmentos de reta (Castro, 2018). Como pode ser observado, as unidades da rede estão organizadas em camadas, com uma camada de entrada, onde a rede recebe as informações, e uma camada de saída, onde se encontram as informações processadas. Cada unidade corresponde a um vetor de entradas ou saídas, que pode variar em número e dimensão. Além disso, a rede pode conter várias camadas ocultas, onde ocorre o processamento dos dados, sendo cada uma composta por uma ou mais unidades (Castro, 2018).




Figura 3.6- Estrutura de uma ANN do tipo Percetrão ( Hanifi et al., 2020)

Entretanto, as entradas de cada camada de uma rede *feedforward* correspondem às saídas da camada anterior, sendo estas influenciadas pelo peso ( $w_i$ ) de cada ligação. Como ilustrado na figura 3.6, todas as saídas de uma camada são direcionadas para as entradas de cada unidade na camada seguinte, podendo cada ligação ter um peso distinto. A saída ( $a$ ) de cada unidade é calculada aplicando uma função de ativação ( $f$ ) à soma de todas as entradas ( $p$ ) (já multiplicadas pelos respectivos pesos ( $w$ )) acrescida de um valor constante ( $b$ ) característico da unidade, conforme mostrado na figura 3.7 e descrito na equação abaixo:

$$a = f \left( \sum wp + b \right) \quad (3.6)$$




Figura 3.7- Funcionamento básico de cada unidade de uma rede do tipo perceptron multicamada (Castro, 2018)

As funções de ativação comumente utilizadas nas unidades de uma rede MLP incluem a função linear, a sigmoide binária e a sigmoide bipolar. Durante o processo de treino da rede, que é supervisionado, ajustam-se os valores dos pesos  $w$  de todas as ligações e das constantes  $b$  de cada unidade. Para que a rede se ajuste da melhor forma possível aos dados fornecidos, normalmente utiliza-se o algoritmo de *backpropagation*, cuja definição e o princípio de funcionamento é descrito a seguir (Castro, 2018).

#### Algoritmo de *backpropagation*

O algoritmo de *backpropagation* é uma técnica fundamental para o treino de redes neurais artificiais, especialmente na previsão da produção de energia eólica. Este algoritmo tem como objetivo minimizar o erro entre o valor previsto pela rede e o valor real medido, além de ajustar os pesos e as constantes de cada unidade da rede. A versão mais básica deste algoritmo é apresentada no fluxograma abaixo:




Figura 3.8 - Fluxograma do Algoritmo MLP - *Backpropagation* (Xu & Mao, 2016)

A figura 3.8 descreve o processo de treino do algoritmo BP, o processo inicia-se com a inicialização dos pesos e constantes da rede, onde os pesos das conexões entre os neurónios e as constantes são atribuídos aleatoriamente ou com valores iniciais. Essa fase é crucial, pois influencia a eficácia do aprendizado.

Após a inicialização, ocorre a importação de dados amostrados. Nesta etapa, os dados de entrada utilizados para treinar a rede são carregados. Em seguida, o algoritmo realiza o cálculo da entrada e saída da camada oculta e da camada de saída. Aqui, as saídas das unidades na camada oculta são calculadas com base nas entradas recebidas e nos pesos definidos, seguido do cálculo da saída da camada de saída.

O próximo passo envolve o cálculo do erro da camada oculta e da camada de saída. Nesta fase, o erro entre a saída prevista pela rede e a saída real (ou esperada) é determinado. Essa avaliação é fundamental para estabelecer como os pesos precisam ser ajustados. Com o erro calculado, realiza-se o ajuste de pesos e constantes da rede para minimizar o erro. Este ajuste, é essencial para a melhoria das previsões da rede.

Após os ajustes, o número de interações é atualizado para monitorar o progresso do treino. Em seguida, uma verificação é feita para saber se todo o processo de treino das amostras está concluído. Se todas as amostras foram processadas, é realizada uma segunda verificação para determinar se a condição de término foi atingida, como um erro aceitável ou um número máximo de épocas.

Finalmente, o processo culmina na fase, onde a rede treinada pode ser utilizada para realizar previsões.

### **3.2.2.3 Redes Neuronal de Função de Base Radial - RBFNN**

O método RBFNN é uma abordagem utilizada para previsão da produção de energia eólica, pertencente à categoria das redes neuronais *feedforward*. Entretanto, como a estrutura MLP, a rede neuronal RBFNN também contém três camadas: a camada de entrada, a camada oculta e a camada de saída, como ilustrado na Figura 3.9. A RBFNN é amplamente utilizada para problemas de aproximação de funções devido à sua capacidade de lidar eficazmente com padrões complexos. Os neurónios da camada oculta na RBFNN utilizam funções de transferência Gaussianas, que são fundamentais para o seu funcionamento. A saída dessas funções de transferência é inversamente proporcional à distância entre o neurónio e o centro da função Gaussiana, o que permite ter uma maior precisão na modelagem de dados não lineares (Lipu et al., 2021).




Figura 3.9 - Estrutura da rede RBFNN para previsão de energia eólica (C. Zhang et al., 2016)

Assim, a saída da rede é expressa pela seguinte equação:

$$\varphi(x) = \sum_{i=1}^N w_i \rho(\|x - c_i\|) \quad (3.7)$$

$\varphi(x)$  - Representa a saída da rede neural de função de base radial para a entrada,  $N$  o número de neurónios,  $x$  o vetor de entrada da rede,  $w_i$  o peso associado ao neurónio da camada oculta,  $\rho$  é a função de base radial (função gaussiana) e  $c_i$  o centro da função de base radial para o neurónio  $i$ .

No método RBFNN, as funções de saída dependem unicamente da distância ao centro do neurónio e todas as entradas são diretamente ligadas ao neurónio oculto. Assim, esta rede oferece várias vantagens em comparação com outras redes neuronais, como a capacidade de aprendizagem simplificada, elevada tolerância ao ruído nas entradas e forte capacidade de generalização. Essas características garantem flexibilidade e uma precisão precisa da produção eólica.

Contudo, existem algumas desvantagens a considerar. Apesar de a velocidade de treino ser mais rápida, o tempo necessário para que a rede neuronal, após estar treinada, processe uma nova entrada e produza uma saída pode ser mais lenta devido à dependência de cada nó na camada oculta.

### 3.2.2.4 Estrutura e Algoritmo *Elman* (ENN)

A rede neuronal recorrente *Elman* é uma rede cuja topologia é semelhante à da rede *feedforward*, a diferença está apenas pelo facto de a *Elman* possuir uma camada de contexto. Esta camada desempenha o papel de uma memória retardada, conferindo à rede *Elman* a capacidade de se adaptar às características das incidências, o que pode refletir diretamente nas características do processo dinâmico (Xu & Mao, 2016). A figura 3.7, ilustra o diagrama da estrutura de uma rede *Elman*:




Figura 3.10 - Estrutura da rede neuronal *Elman* (Xu & Mao, 2016)

Como pode ser observado na figura acima, a rede neuronal *Elman* é estruturada com uma camada de entrada, uma ou várias camadas ocultas, camada de contexto e camada de saída. A camada de entrada funciona apenas como uma interface de entrada, enquanto a camada oculta pode utilizar uma função de transferência não linear ou linear. A camada de saída realiza uma função de ponderação linear.

De acordo (Xu & Mao, 2016), uma característica única da rede neuronal *Elman* é a sua capacidade de armazenar a saída do passo de tempo anterior e realimentá-la na entrada. Este mecanismo permite que a camada oculta alcance o armazenamento retardado, o que melhora a capacidade da rede de capturar padrões temporais. Consequentemente, a rede neuronal *Elman* é capaz de se adaptar e refletir as características dinâmicas dos eventos de entrada, tornando-a particularmente eficaz para processos e sequências dependentes do tempo.

Lipu et al. (2021) destacam que a rede ELM é eficaz na previsão de resultados em sistemas não lineares e complexos devido à sua elevada adaptabilidade, capacidade superior de prever operações contínuas, rapidez de aprendizagem e menor complexidade computacional, o que a posiciona como uma opção mais elevada em comparação com outras redes neuronais.

Uma das principais vantagens da rede ELM é a sua capacidade um treino rápido, porém ele também apresenta algumas desvantagens, como o problema de *overfitting* (Lipu et al., 2021).

#### **Algoritmo Elman**

Conforme descrito, a rede neuronal de *Elman* é desenvolvida com base na rede neuronal *backpropagation* e é uma rede neuronal dinâmica. Deste modo a *Elman* utiliza o mesmo algoritmo que a rede neuronal *backpropagation*, descrito na figura 3.6.

#### **3.2.2.1 Metodologia de Previsão**

Para realizar previsões com sucesso, o primeiro passo consiste em processar os dados com uma rede neuronal selecionada, como por exemplo, uma rede perceptrão multicamada. Em seguida, é necessário definir a estrutura da rede, incluindo o número de camadas escondidas e o número de unidades existente em cada camada escondida.

Contudo, conforme mencionado por Castro (2018), devido à dificuldade em estabelecer uma metodologia objetiva para esta tarefa, muitas vezes utiliza-se o método de tentativa-erro na prática. Este método consiste em testar vários valores e escolher a solução que proporciona os melhores resultados. Depois, é preciso organizar os dados em pares de vetores de entrada e de saída desejada para que estes possam ser apresentados à rede para o treino. A quantidade de entradas a apresentar à rede pode ser determinada com base no cálculo dos coeficientes de autocorrelação entre os elementos da sequência de entrada ou através de testes exaustivos com diferentes números de entradas. Finalmente, após estruturar os dados, eles são apresentados à rede, e os valores dos pesos e constantes são calculados utilizando o algoritmo de *backpropagation*. Uma vez concluído o treino, a rede pode ser usada para realizar previsões de valores futuros, apresentando novos vetores de entrada para obter as saídas correspondentes.

Em suma as ANN, especialmente as redes perceptrão multicamada, oferecem uma abordagem robusta para a previsão da produção de energia eólica, permitindo uma gestão mais eficiente e otimização dos recursos energéticos. Apesar dos desafios na configuração inicial e no treino, o seu uso proporciona previsões precisas e confiáveis, essenciais para o setor energético.

### 3.2.3 Método de Referência - Persistência

No que diz respeito ao método de referência, este é geralmente utilizado como termo de comparação de desempenho, dos vários métodos de previsão descritos anteriormente. O método de persistência assume que a energia eólica futura será igual à potência medida no presente, ou seja, segue a regra básica de que *"hoje é igual a amanhã"*. Portanto, o objectivo deste método é comparar novos métodos de previsão, a fim de avaliar as suas melhorias (Dutta et al., 2017; Hanifi et al., 2020).

No entanto, segundo Castro (2018), o método de persistência apresenta bons resultados em previsões com uma hora de antecedência. Neste caso, o valor previsto é igual ao último valor conhecido da série. Para um horizonte de previsão de N horas, a previsão é igual aos últimos N valores conhecidos da série. No entanto, a precisão deste método tende a diminuir rapidamente à medida que a escala temporal de previsão aumenta.

Um dos motivos para a ampla adoção deste método em previsões de curto prazo de energia eólica é a frequência com que o potencial eólico varia, sem seguir um padrão diário fixo para a geração eólica (Hanifi et al., 2020). É importante destacar também que este método é difícil de superar, especialmente em previsões de curto prazo, devido à característica inerentemente persistente do vento.

#### 3.2.3.1 Metodologia de Previsão

Para realizar previsões usando o método de persistência, inicialmente é necessário medir a potência do vento em tempo real. Esses dados iniciais podem ser obtidos na base de dados do Sistema de Supervisão e Aquisição de Dados SCADA, provenientes de medições realizadas com anemômetros instalados nas turbinas eólicas. Com isso, a potência medida no momento atual é projetada para o futuro. Por exemplo, se a potência medida for de 100 MW, o método de persistência assume que essa potência será de 100 MW em um determinado tempo futuro (de segundos até 1 hora).

### 3.2.4 Métodos Híbridos

A integração de diversos modelos de previsão descritos acima, resulta nos chamados modelos híbridos ou combinados. Assim, ao combinar modelos, consegue-se maximizar as informações disponíveis, alcançar previsões mais precisas em diversos cenários, testar diferentes modelos para condições específicas e gerar novos resultados que não seriam obtidos se os modelos fossem utilizados de forma isolada (Hanifi et al., 2020; Koehler, 2021).

Como descrito anteriormente, os métodos de previsão isolados possuem vantagens e desvantagens únicas, o que leva à criação de modelos combinados para obter resultados mais precisos do que utilizar um único método. Para efetivar a criação de um modelo híbrido que apresente maior precisão, foram desenvolvidas técnicas que consideram fatores como o horizonte temporal, a disponibilidade de dados e o tempo de processamento. Essas técnicas estão organizadas em quatro categorias:

**Modelos combinados baseados em ponderação:** nestas abordagens, utiliza-se a combinação ponderada dos resultados de diferentes modelos baseados em séries temporais, atribuindo pesos específicos a cada modelo para melhorar a precisão. Para avaliar os resultados, seleciona-se uma métrica de desempenho específica e, em seguida, calculam-se os coeficientes de ponderação para cada um dos modelos. Por fim, estes coeficientes são combinados para gerar uma previsão final, conforme ilustrado na figura 3.11:




Figura 3.11-Fluxograma de métodos de combinação (adaptado d B. Yang et al., 2021)

**Modelos combinados baseados no pré-processamento de dados:** Esta abordagem concentra-se em melhorar a qualidade dos dados antes de serem utilizados pelos modelos, para evitar encargos computacionais desnecessários, removendo características de dados redundantes. Este processo é realizado por meio de decomposição da série temporal de velocidade do vento bem como a da potência em equações mais regulares e fáceis de prever. Em seguida, cada componente é previsto separadamente antes da combinação das previsões. Como resultado, obtêm-se dados mais previsíveis e com informações reais, fazendo com que haja um aumento na precisão e redução no tempo de cálculo, a figura 3.12 ilustra como é feito essa abordagem (B. Yang et al., 2021; Koehler, 2021).




Figura 3.12- Pré-processamento de dados (Adaptado de Yang et al., 2021)

**Modelos combinadas baseadas em otimização de parâmetros:** essas abordagens envolvem a ajustagem e otimização dos parâmetros dos modelos para maximizar sua precisão e eficiência. A figura 3.13 ilustra como é feito este processamento de maneira simples.




Figura 3.13- Seleção e otimização de parâmetros do modelo (Adaptado de Yang et al., 2021)

**Modelos combinadas baseadas em pós-processamento de dados:** Essas abordagens concentram-se em ajustar e corrigir os resultados após a aplicação dos modelos, minimiza os erros sistemáticos e melhora desta feita a qualidade final das previsões. Nestes modelos, as previsões finais são ajustadas utilizando modelos de previsão de erros, que seguem três etapas: Primeiro, desenvolver um modelo de previsão inicial e calcular os erros, segundo, criar modelos de previsão para os erros residuais; e terceiro, atualizar o modelo de previsão inicial através da previsão dos erros residuais e obter os resultados (Yang et al., 2021). A figura 3.14 apresenta o fluxograma generalizado desse processo.




Figura 3.14 - Abordagem combinada baseada em pós-processamento (Adaptado de Yang et al., 2021)

No entanto, essa combinação pode nem sempre levar a um resultado melhor em comparação com seus modelos individuais. Contudo, alguns estudos comprovam que a probabilidade de obter resultados imprecisos e inferior. Para efetivar essa melhoria nos métodos de previsão, diversos métodos híbridos têm sido propostos com base na combinação de diferentes modelos (Hanifi et al., 2020). A tabela 3.3 ilustra alguns dos métodos híbridos existentes.

Tabela 3.3 - Alguns Modelos Híbridos utilizados para previsão do vento

| Referências               | Métodos                           | Tipo de Combinação                                 | Vantagens                                                                        | Desvantagens                                                                                       |
|---------------------------|-----------------------------------|----------------------------------------------------|----------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------|
| (Hong & Ríoflorido, 2019) | CNN, RBFNN, DGF                   | Redes Neurais Artificiais                          | Alta capacidade de modelagem, pode capturar características complexas dos dados. | Alto custo computacional, pode necessitar de grandes quantidades de dados para treino eficiente    |
| (Lin et al., 2020)        | IF e DL NN                        | Algoritmos de Detecção e Redes Neurais Artificiais | Eficiente na detecção de anomalias, boa capacidade de modelagem                  | Complexidade na implementação, ajuste de parâmetro                                                 |
| (Lima et al., 2017)       | ARMA e Filtro de Kalman           | ARMA e Filtro de Kalman                            | Bom para sistemas lineares e ruído gaussiano                                     | Limitações em sistemas não-lineares, sensível a erros de modelagem                                 |
| (De Giorgi et al., 2011)  | Rede Elman e MLP                  | Redes Neurais Artificiais                          | Capacidade de modelar dependências temporais e relações não-lineares             | Pode ser difícil de treinar, sensível a um conjunto elevado de parâmetros na entrada               |
| (De Giorgi et al., 2011)  | Decomposição Wavelet e rede Elman | Redes Wavelet e Rede Neuronal de Elman             | Boa análise de frequências temporais, capta dependências temporais.              | Complexidade de implementação, necessidade de escolha adequada de wavelets                         |
| (P. Zhao et al., 2012)    | Filtro de Kalman e MLP            | Filtro Kalman e MLP                                | Remoção eficiente de ruído, capacidade de modelar não-linearidades.              | Complexidade de implementação, capacidade computacional elevada                                    |
| (Lin et al., 2020)        | Rede neuronal feed-forward e IF   | ANN e IF                                           | Simplicidade de implementação, e bom desempenho.                                 | Limitada capacidade de modelar dependências temporais, pode ser menos eficiente em dados complexos |

#### 3.2.4.1 Método CNN, RBFNN, DGF

Este método híbrido combina CNN, RBFNN e DGF. Entretanto, neste método, as CNN são empregues para extrair características complexas dos dados, aproveitar a sua capacidade de reconhecer padrões em dados espaciais ou temporais. As características extraídas são então processadas por RBFNN, que são eficazes na realização de tarefas de classificação ou regressão com base nas características dos dados fornecidos. O DGF é utilizado para otimizar diretamente a função de perda durante a fase do treino da rede. Esta combinação permite uma modelagem robusta e detalhada, capaz de capturar relações complexas nos dados. No entanto, o método apresenta desvantagens significativas, como o elevado custo computacional e a necessidade de grandes volumes de dados para um treino eficaz (Hong & Rioflorido, 2019).

#### 3.2.4.2 Método IF e DLNN

Este método combina o IF com DLNN. O IF é uma técnica eficiente para a deteção de anomalias, identificar padrões que se desviam significativamente do comportamento esperado. Paralelamente, DLNN são empregues para modelar e prever a produção com base nos dados históricos tratados. Este método tira proveito das forças de ambos os métodos, primeiro a capacidade do IF para identificar anomalias e dados atípicos, segundo a robustez das DL na modelagem de relações complexas. No entanto, a implementação deste método pode ser complexa, e o ajuste dos parâmetros da rede neuronal na fase de treino exige cuidados adicionais para garantir um desempenho ótimo (Lin et al., 2020).

#### 3.2.4.3 Método ARMA com Filtro de *Kalman*

Este método combina o modelo ARMA com o Filtro de *Kalman* para a modelagem de séries temporais. Os modelos ARMA são aplicados para ajustar curvas e captar a dinâmica dos dados temporais. Este método revela-se particularmente eficaz em contextos lineares e com a presença de ruído gaussiano. O Filtro de *Kalman* é utilizado para estimar o estado de sistemas lineares dinâmicos, ao filtrar o ruído e, assim, melhorar a precisão das estimativas. No entanto, este método apresenta limitações quando aplicado a sistemas não-lineares e pode ser sensível a erros de modelagem, o que pode comprometer a precisão das previsões (Lima et al., 2017).

#### 3.2.4.4 Rede *Elman* com MLP

Este método combina a rede neuronal recorrentes *Elman* com redes neurais perceptrão multicamadas. A Rede *Elman* nesta técnica é empregue para capturar dependências temporais

devido à sua estrutura recorrente, enquanto as MLP são empregues para modelar relações não-lineares complexas. Esta combinação permite uma modelagem mais completa das dinâmicas temporais e das relações não-lineares nos dados. No entanto, o método pode ser difícil de treinar devido à necessidade de ajustar um elevado número de parâmetros e pode enfrentar desafios relacionados à convergência durante o treino (De Giorgi et al., 2011).

#### **3.2.4.5 Decomposição *Wavelet* e Rede *Elman***

Este método combina a decomposição *Wavelet* com a rede *Elman*. A decomposição *Wavelet* é utilizada para analisar sinais em diferentes escalas e frequências temporais, proporcionando uma visão detalhada das variações nos dados. A rede *Elman* é, então, aplicada para modelar as dependências temporais identificadas pela decomposição. Este método revela-se eficaz na análise de dados com frequências temporais e na captura de dependências temporais complexas (De Giorgi et al., 2011).

#### **3.2.4.6 Filtro de Kalman e MLP**

Este método faz uma combinação do Filtro de *Kalman* com a rede MLP. O Filtro de *Kalman* é utilizado para remover ruídos dos dados, enquanto a MLP é empregue para modelar as não-linearidades remanescentes dos dados e realizar previsões baseadas nos dados filtrados. Este método é eficaz na remoção de ruído e na modelagem de relações não-lineares e proporcionar previsões mais precisas. No entanto, a complexidade na implementação e a elevada complexidade computacional são desafios associados este método (P. Zhao et al., 2012).

### **3.3 Critérios para Avaliação dos Métodos de Previsão**

No que diz respeito à análise comparativa dos métodos de previsão, este pode ser realizado tendo em consideração diversos critérios, tais como precisão, o horizonte temporal, tempo de computação, características de entrada (as propriedades das series temporais a serem previstos), complexidade dos modelos e escalabilidade (Hanifi et al., 2020). A seguir, serão detalhados os critérios utilizados para avaliar o desempenho dos métodos de previsão e, com base nestas métricas, escolher o método que apresentar as melhores características.

#### **3.3.1 Medição da Precisão**

Quando analisamos o desempenho dos métodos de previsão, segundo Hanifi et al. (2020), é necessário considerar várias métricas de medição estatísticas normalmente utilizadas

para avaliar a precisão desses métodos. Essas métricas podem mostrar os desvios entre a potência prevista e a potência medida. Desta feita, de acordo com algumas bibliografias revisadas no estado da arte, a maioria dos estudos utilizou um número seletivo de critérios de avaliação da precisão, como NMAE, RMSE, NRMSE e MAPE, MAE. Entretanto, as métricas RMSE, MAE e MAPE, são as frequentemente mais utilizados, enquanto NMAE, NRMSE e R<sup>2</sup>, são utilizados ocasionalmente (Piotrowski et al., 2022). A seguir, são apresentados detalhadamente os tipos de técnicas para avaliar a precisão dos métodos de previsão de energia eólica.

### 3.3.1.1 Erro Normalizado

Em relação às métricas de erro, a métrica comumente utilizada para avaliar o desempenho, especificando o grau de semelhança entre os valores previstos e os valores reais, é a equação 3.7, definido abaixo, (Hanifi et al., 2020):

$$E_t(l) = Y_N(t, l) - Y_N^*(t, l) \quad (3.8)$$

$$Y_N^*(t, l) = \frac{Y^*(t, l)}{\text{Max}_{t=1}^M(Y(t, l))} \quad (3.9)$$

$$Y_N(t, l) = \frac{Y(t, l)}{\text{Max}_{t=1}^M(Y(t, l))} \quad (3.10)$$

Onde:  $E_t$  representa o erro no instante  $t$ ,  $Y_N(t, l)$  o valor medido normalizado no instante  $t$  (é o valor medido do banco de dados SCADA),  $Y_N^*(t, l)$  o valor previsto normalizado para instante  $t$ ,  $l$  indica o horizonte de tempo de previsão, e salientar que  $t$  representa hora dos dados medidos e previstos,  $Y_i^*$  é o valor previsto e  $Y_i$  é o valor real.

As equações 3.9 e 3.10, mostram como encontrar os valores normalizados, onde  $M$  representa o número total de dados previstos.

### 3.3.1.2 Erro Médio Percentual Absoluto - MAPE (%)

Segundo Piotrowski et al. (2022), O MAPE, conforme descrito na Equação 3.11, mede o erro percentual em relação ao valor real e é representado como a média das razões. Essa métrica é frequentemente utilizada para comparar diferentes modelos.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_i - Y_i^*}{Y_i} \right| \times 100\% \quad (3.11)$$

Onde:  $N$  representa no número de amostras.

### 3.3.1.3 Erro Absoluto Médio - MAE

O MAE, conforme apresentado na Equação 3.12, representa o nível estimado de erro absoluto, indica desta feita a magnitude média entre os valores reais e os valores previstos (Zheng & Wu, 2019). Por não ser sensível a valores atípicos, o MAE pode refletir com mais precisão o estado real dos erros previstos (Zheng & Wu, 2019). Um modelo é considerado preciso quando o MAE se aproxima de zero.

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_i - Y_i^*| \quad (3.12)$$

### 3.3.1.4 Raiz do Erro Quadrático Médio - RMSE

O RMSE apresentado na Fórmula 3.13, é uma métrica quadrática que estima a magnitude média do erro. É amplamente utilizada para medir a diferença entre os valores previstos e os valores observados, ela reflete a discrepância entre os valores reais e os estimados, ou seja, a magnitude absoluta do erro de previsão. No entanto, o RMSE é sensível a valores atípicos, pode ser influenciado se os dados contiverem *outliers* (Piotrowski et al., 2022).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - Y_i^*)^2} \quad (3.13)$$

Embora o RMSE seja normalmente utilizado para expressar a dispersão dos resultados, o MAE e o MAPE podem indicar o desvio da previsão. Quanto menores forem os valores de RMSE, MAE e MAPE, mais preciso será o modelo de previsão utilizado (Piotrowski et al., 2022).

Em determinadas situações, os autores necessitam normalizar o MAE e o RMSE para avaliar quantitativamente o desempenho de previsão de alguns métodos. Suas normas são representadas pelo erro absoluto médio normalizado (NMAE) e pelo erro quadrático médio normalizado (NRMSE), que são definidos a seguir:

### 3.3.1.5 Erro Absoluto Médio Normalizado - NMAE

O NMAE é uma métrica bastante relevante a considerar no critério de avaliação da precisão dos métodos de previsão de produção da energia eólica. Esta métrica definida na equação 3.14 proporciona uma análise mais precisa dos erros, incluindo tanto os aleatórios como os sistemáticos (Hanifi et al., 2020).

Onde  $C_i$ , representa a capacidade operacional do ponto de tempo  $i$ . Em geral, valor menor dessa métrica indica que a solução correspondente oferece menos desvio no desempenho da previsão.

$$NMAE(l) = \left( \frac{1}{N} \sum_{t=1}^N \left| \frac{Y_t - Y_t^*}{C_t} \right| \right) \times 100\% \quad (3.14)$$

Onde:  $C_i$  representa o valor normalizado, utilizado para dimensionar a diferença entre os valores reais e os previstos.

### 3.3.1.6 Raiz do Erro Quadrático Médio Normalizado - NRMSE

Outro fator amplamente utilizado para verificar a precisão dos métodos de previsão é o NRMSE, definido na equação 3.15. Assim como o NMAE, o NRMSE analisa os erros aleatórios e sistemáticos.

$$NRMSE(l) = \sqrt{\frac{1}{M} \sum_{t=1}^M \left( \frac{Y_t - Y_t^*}{C_t} \right)^2} \times 100 \quad (3.15)$$

Entretanto, os valores mais altos de NRMSE indicam maiores desvios, enquanto previsões mais precisas apresentam valores mais baixos de NRMSE. Além disso, uma grande diferença entre NMAE e NRMSE nos resultados de um método indica que os valores previstos estão extremamente dispersos em relação aos dados medidos (Hanifi et al., 2020).

### 3.3.1.7 Coeficiente de Determinação - R-Square ( $R^2$ )

O coeficiente de determinação é uma métrica bastante útil para avaliar o desempenho de um método de previsão. O  $R^2$  indica a variância da previsão em relação aos dados medidos. No entanto,  $R^2$  varia entre 0,0 e 1,0 onde o 1 indica um ajuste perfeito enquanto os valores negativos indicam uma previsão pior. Ele pode ser definido como:

$$R^2 = 1 - \frac{\sum_{i=1}^n [(Y_i^*)_k - (Y)_i]^2}{\sum_{k=1}^n \left[ (Y)_k - \frac{1}{n} \sum_{k=1}^n (Y)_i \right]^2} \quad (3.16)$$

Na equação acima, o numerador representa a soma dos erros quadrados, que indica o quanto os valores previstos diferem dos valores medidos enquanto o denominador representa a soma total dos quadrados, que é uma medida da variância total nos dados medidos. De salientar que  $P_{medido}$  é o valor medido do banco de dados SCADA.

### 3.3.1.8 Erro de Amplitude e de Fase

O erro de amplitude é a métrica que verifica se a potência prevista está acima ou abaixo do esperado, enquanto o erro de fase surge de um desfasamento temporal entre os dados previstos e os dados reais. A partir desses dois tipos de erros, apresentados na equação 3.17 e 3.18, é possível definir o erro de desvio padrão (Hanifi et al., 2020):

$$SDE = \sqrt{\frac{1}{M-1} \sum_{l=1}^M (E_i(l) - \hat{E}(l))^2} \quad (3.17)$$

$$SDE^2 = SD^2 + DISP^2 \quad (3.18)$$

Onde:  $\hat{E}(l)$ , representa o erro médio normalizado,  $SD$ , indica o erro da amplitude e o  $DISP$  indica o erro da fase.




Figura 3.15 - Erros da amplitude e fase da Previsão de Energia Eólica (Jyothi & Rao, 2016)

Entretanto, para as duas métricas indicadas acima, valores próximos de zero indicam melhores precisões nas previsões, enquanto valores elevados indicam piores precisões.

Tabela 3.4 - Avaliação de desempenhos dos métodos de previsão com base as métricas estatísticas

| Referência           | Método/Algoritmo | Métrica de avaliação | Valor de avaliação | Resultados                                                                                                                                                                                                                                                                                                                     |
|----------------------|------------------|----------------------|--------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| (Castro, 2018)       | ARMA             | MAE                  | 0,56               | Neste estudo o ARMA conseguiu um desempenho melhor em relação ao método ANN, para previsão a curto prazo. O ANN mostrou-se relativamente menos preciso em relação ao método ARMA, para horizonte de curto prazo. Uma das vantagens de ANN neste caso de estudo foi o tempo treino, que foi inferior em relação ao método ARMA. |
|                      |                  | RMSE                 | 0,94               |                                                                                                                                                                                                                                                                                                                                |
|                      |                  | MAPE (%)             | 15,87              |                                                                                                                                                                                                                                                                                                                                |
| (Castro, 2018)       | ANN              | MAE                  | 0,63               |                                                                                                                                                                                                                                                                                                                                |
|                      |                  | RMSE                 | 0,97               |                                                                                                                                                                                                                                                                                                                                |
|                      |                  | MAPE (%)             | 18,33              |                                                                                                                                                                                                                                                                                                                                |
| (Bilal et al., 2018) | ANN-MLP          | NMAE                 | 3,51               | Neste estudo verificou-se que ao utilizar a velocidade do vento e a temperatura como entrada é mais eficaz do que usar apenas a velocidade do                                                                                                                                                                                  |
|                      |                  |                      | 14,85              |                                                                                                                                                                                                                                                                                                                                |

|                                   |                        |                                           |                               |                                                                                                                                                                                                              |
|-----------------------------------|------------------------|-------------------------------------------|-------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|                                   |                        | NRMSE (%)<br>$R^2$                        | 0,98                          | vento. Levar em conta todas as variáveis melhora o desempenho significativamente.                                                                                                                            |
| (Carolin Mabel & Fernandez, 2008) | ANN - MLP              | RMSE (%)                                  | 8,06                          | Método apresentou um desempenho melhor em comparação aos métodos de referência, e foi útil para os planeadores energia.                                                                                      |
| (Xu & Mao, 2016)                  | Elman ANN              | RMSE (%)<br>MAE (%)                       | 16,55<br>10,52                | Aplicação de uma rede com camada contexto, melhorou significativamente a precisão em comparação com o método de persistência.                                                                                |
| (Sideratos & Hatzigiorgiou, 2007) | RBFNN                  | NMAE (%)<br>NRMSE (%)                     | 5-14<br>20                    | Previsões eficazes para 1-48 horas à frente tiveram um desempenho superior ao método de persistência.                                                                                                        |
| (Jyothi & Rao, 2016)              | AWNN                   | RMSE                                      | 0,16                          | O menor RMSE demonstrou que a WNN apresenta um bom desempenho em relação ao MLP padrão.                                                                                                                      |
| (Hong & Rioflorido, 2019)         | CNN,<br>RBFNN,<br>DGF  | $R^2$<br>RMSE (%)<br>NMSE (%)<br>MAPE (%) | 0,92<br>76,97<br>2,75<br>5,05 | O desempenho superior foi observado em comparação com as redes neurais CNN, RBFNN e MLP, apresentando métricas significativamente melhores.                                                                  |
| (De Giorgi et al., 2011)          | Rede Elman e MLP       | MAE (%)                                   | 10,98                         | Entre os vários dados dos NWP, a pressão e a temperatura foram os que tiveram o maior impacto positivo. O método híbrido teve um desempenho superior aos outros métodos, especialmente para horizonte de 24h |
| (De Giorgi et al., 2011)          | Wavelet e rede Elman   | MAE (%)                                   | 15,50                         |                                                                                                                                                                                                              |
| (P. Zhao et al., 2012)            | Filtro de Kalman e MLP | NRMSE (%)                                 | 16,47                         | Neste estudo verificou-se que valor de NRMSE reduziu de 17,81% para 16,47% com a aplicação do filtro de Kalman no método MLP                                                                                 |
| (Catalão et al., 2011)            | MLP                    | MAPE (%)                                  | 7,26                          | Neste estudo, verificou-se uma melhoria na precisão e no tempo computacional em relação ao método de persistência                                                                                            |

A avaliação de desempenho de modelos de previsão de energia eólica, conforme descrita na tabela, revela uma variedade de métodos e algoritmos aplicados, cada um medido através de diferentes métricas de avaliação. No estudo de Castro (2018), o modelo ARMA obteve um MAE de 0,56, RMSE de 0,94 e MAPE de 15,87%, o que demonstrou melhor desempenho em previsão de curto prazo comparado ao modelo ANN, que apresenta um MAE de 0,63, RMSE de 0,97 e MAPE de 18,33%. Bilal et al. (2018) mostram que o modelo ANN-MLP, ao utilizar tanto a velocidade do vento quanto a temperatura como entradas, alcança NMAE de 3,51%,

NRMSE de 14,85% e um  $R^2$  de 0,98, indicando que incluir múltiplas variáveis melhora significativamente a precisão.

Outros estudos destacam métodos híbridos e redes neurais. Carolin Mabel & Fernandez (2008) utilizam ANN-MLP e obtêm um RMSE de 8,06%, evidenciando um desempenho superior aos métodos de referência. Xu & Mao (2016) mostram que a aplicação de uma rede Elman ANN melhora a precisão com RMSE de 16,55% e MAE de 10,52%. Sideratos & Hatzargyriou (2007) demonstram que a RBFNN apresenta previsões eficazes para 1-48 horas à frente com NMAE entre 5-14% e NRMSE de 20%. Além disso, o estudo de Hong & Rioflorido (2019) indica que uma combinação de CNN, RBFNN e DGF supera outras redes neurais com um R de 0,92 e um RMSE de 76,97%. Estes resultados sublinham a importância de escolher o método apropriado e considerar múltiplas variáveis para melhorar a precisão das previsões de energia eólica.

A seguir, serão analisados dois relatórios de precisão da produção de energia eólica apresentados pela State Grid Corporation e alguns gráficos que mostram o NME, NMAE e NRMSE, referentes aos meses de Maio e Abril de 2021. Os valores dessas métricas sustentam as informações recolhidas em vários estudos práticos. Por exemplo, alguns estudos mencionam que a taxa de MAPE deve estar dentro de 10% da capacidade instalada para a maioria dos modelos.

Por outro lado, a State Grid Corporation concluiu em alguns estudos que, para a China, um NRMSE de 20% é o valor máximo aceitável para previsões de energia eólica de curto prazo e 15% para a previsão de 4 horas à frente. Dessa forma, métodos que apresentarem um NRMSE mais alto terão menos precisão. Na Irlanda, os gestores do sistema segundo a EirGrid e SONI exigem uma precisão que varia de 6 a 8%.

Portanto, os requisitos para as métricas de medição de previsão de produção de energia eólica não são uniformemente definidos. Cada país pode ter as suas próprias especificações baseadas em suas condições locais e os regulamentos vigentes.




Figura 3.16 - Relatório da precisão da produção de energia eólica Abril de 2021 (fonte: [EirGrid &](#)




Figura 3.17 - Relatório da precisão da produção de energia eólica Maio de 2021 (fonte: [EirGrid & SONI](#))

### 3.3.2 Tempo Computacional

O tempo computacional que um método leva para apresentar os resultados é outro fator a levar em consideração aquando de comparação dos métodos de previsão. Entretanto, o

tempo computacional necessário de método de previsão pode variar bastante, pois este processo depende de diversos fatores, como os tipos de métodos utilizados, a precisão requerida, o volume e a taxa de amostragem dos dados de entrada, o computador utilizado (Hanifi et al., 2020). Os métodos baseados em inteligência artificial, por exemplo apresentam um tempo computacional reduzido, quando comparado com os métodos baseados em séries temporais (ARMA e ARIMA).

De salientar que, a precisão das previsões e o horizonte de tempo desejado influenciam significativamente o tempo computacional. Por exemplo, as previsões de curto prazo, podem ser mais rápidas, mas ainda assim, em alguns casos requerem processamento significativo para garantir um bom desempenho.

Em alguns estudos práticos, verificou-se que alguns modelos exigiam cerca de 60 a 70 minutos de tempo computacional para cada simulação de modelo baseados em NWP de 72 horas. Além disso, o algoritmo de treino também influencia no tempo de processamento. Por exemplo, no caso de estudo elaborado pelo Y. Zhao et al. (2016), a ELM com rede neuronal *feedforward* apresentou um desempenho computacional mais rápido em comparação com redes baseadas no algoritmo de *backpropagation*.

Já no trabalho concluído por Singh et al. (2007), foi verificado que o treino e teste de dois meses de dados de entrada com uma taxa de amostragem de 10 minutos para a rede MLP proposta pode ser concluído em 30 minutos em um computador de baixa capacidade. Os autores também destacaram que o uso de uma rede neuronal individual para cada turbina, em vez de uma única rede para todo o parque eólico, assegura um treino mais rápido devido à redução do tamanho de dados de treino e da complexidade da rede. Além disso, essa abordagem evita que os modelos sejam afetados por turbinas que estejam fora de operação.

Portanto, o tempo computacional é um aspecto relevante na seleção do método de previsão mais adequado, especialmente quando se considera a aplicação em tempo real e a necessidade de equilibrar precisão e eficiência computacional.

### **3.3.3 Parâmetros de Entrada**

Escolher as variáveis de entrada apropriadas é essencial para construir um modelo de previsão eficiente. No entanto, quanto mais variáveis forem apresentadas na entrada, melhor será a análise e mais precisas serão as previsões. Portanto, um fator crítico na seleção do modelo de previsão de energia eólica mais eficiente é a escolha das melhores características de

entrada do sistema. Esta seleção é fundamental para se obter uma maior precisão nos modelos de previsão.

Assim, para o modelo físico, aplicam-se considerações físicas para prever a velocidade e direção do vento, e as variáveis de entrada serão informações físicas ou meteorológicas, como a descrição da orografia, rugosidade, obstáculos e clima. Já para um modelo estatístico, utilizam-se os dados históricos do vento ou de produção do parque eólico. Desta forma, o método físico funciona como uma análise preliminar, cujos resultados melhoram a eficiência do método estatístico.

Além disso, nos estudos de casos práticos e na revisão bibliográfica, verificou-se que a velocidade do vento é, de longe, a variável de entrada mais utilizada para a previsão de energia eólica.

A Figura 3.15 apresenta as estatísticas compiladas por Hanifi et al. (2020) sobre as diversas características de entrada comumente utilizadas. É notável que, além da velocidade do vento, variáveis como temperatura, direção do vento, densidade do ar, humidade relativa e pressão atmosférica são frequentemente incluídas nos estudos analisados.




Figura 3.18- Estatísticas dos parâmetros de entrada (Hanifi et al., 2020)

### 3.4 Análise Comparativa Segundo os Critérios Utilizados

Para realizar uma análise comparativa entre os diferentes métodos de previsão, é essencial considerar que cada método apresenta vantagens e desvantagens específicas, dependendo do horizonte temporal da previsão, das características (parâmetros de entrada) dos dados

disponíveis, a complexidade computacional, o tempo de treino, a precisão e as condições locais e regulamentos.

Com base na análise detalhada dos métodos descritos acima, tornou-se evidente que os métodos físicos são mais adequados para previsões a longo prazo e para a gestão de grandes instalações eólicas. No entanto, esses métodos exigem maior poder computacional e são mais suscetíveis a erros sistemáticos.

Entre os métodos estatísticos, as séries temporais (ARMA e ARIMA) são ideais para previsões a curto prazo, porém, estes modelos, apresentam também certas limitações como o tempo computacional necessário para realizar as previsões e ao lidar com dados ruidosos e não lineares. Por outro lado, as redes neurais artificiais têm a capacidade de lidar com padrões complexos e não lineares, e em maioria dos cenários de previsão a curto prazo podem apresentar elevada precisão em comparação com os métodos ARMA e ARIMA. No entanto, alguns algoritmos podem apresentar bom desempenho computacional, ou seja, menor tempo de processamento, enquanto outros podem apresentar alta complexidade computacional e necessitarem de grandes volumes de dados para serem mais precisos.

Por fim, os métodos híbridos, ao combinarem as vantagens dos métodos físicos e estatísticos, podem oferecer alta precisão e confiabilidade em comparação com os métodos de referência. No entanto, essa abordagem resulta em maior complexidade computacional.

A tabela 3.5 a seguir fazem um resumo comparativo entre os métodos de previsão descritos acima e os critérios de avaliação:

Tabela 3.5- Abordagem comparativa dos métodos de previsão da energia

| Métodos                     | Descrição                                                                                                        | Vantagens                                                                                                  | Desvantagens                                                                                                                                  |
|-----------------------------|------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------|
| <b>Métodos Físicos</b>      | Utilizam dados atmosféricos em tempo real para fazer previsões dos dados meteorológicos.                         | Alta precisão em previsões de longo prazo. Eficaz na gestão de instalações eólicas de grande escala.       | Altos requisitos computacionais. Tempos de resposta lentos e altas taxas de erro.                                                             |
| <b>Métodos Estatísticos</b> | Utilizam modelos baseados em dados históricos para prever a velocidade, potência do vento, ou produção elétrica. | Rápido e eficaz para previsões de curto prazo. tempo de treino reduzido.                                   | Alguns modelos podem ser limitados na modelagem de relações não lineares e o desempenho pode degradar com dados de com elevado grau de ruído. |
| <b>Híbridos</b>             | Combinam as forças dos métodos físicos e estatísticos para criar modelos mais complexos.                         | Ampla aplicabilidade utiliza diferentes tipos e estruturas de dados. Alta precisão e previsões confiáveis. | Complexidade do modelo e altos requisitos de treino. Custos de implementação e manutenção.                                                    |

Assim, a decisão sobre a escolha do método de previsão mais adequado deve levar em consideração vários fatores, como o horizonte temporal da previsão, a capacidade de produzir menos erros de precisão em comparação com outros métodos, a disponibilidade e qualidade dos dados, os recursos computacionais disponíveis e as necessidades específicas da gestão para a produção de energia elétrica através de recursos eólicos.

Contudo, para garantir uma escolha adequada, é fundamental avaliar cuidadosamente o contexto e os objetivos específicos da previsão, ajustar o método conforme necessário para atender às particularidades de cada situação.

### **3.5 Técnicas Implementadas para o Aperfeiçoamento da Precisão dos Métodos**

A maioria dos esforços atuais de modelação para prever a produção de energia eólica visa reduzir os erros de previsão. Para melhorar a precisão desses métodos, têm sido implementadas diversas técnicas. A seguir, serão apresentadas algumas dessas técnicas:

#### **3.5.1 Filtro *Kalman***

O Filtro *Kalman* é um algoritmo que processa conjuntos de dados com ruído estatístico e outras imprecisões. Este algoritmo estima variáveis que representam a tendência desses dados, utiliza as distribuições de probabilidade aplicadas a essas variáveis.

Por exemplo, a precisão dos dados de NWP exerce um papel crucial na precisão da previsão de energia eólica. Uma estratégia eficaz para melhorar o desempenho é reduzir a incerteza nos dados de NWP. Nesse sentido, o algoritmo de filtragem de *Kalman* é aplicado não apenas para eliminar erros sistemáticos, mas também para otimizar a estimativa por meio da combinação de observações ponderadas recentes, o que ajuda a mitigar vieses associados. Além disso, este filtro possui capacidade de adaptação rápida a mudanças nas observações, o que dispensa a necessidade de longas séries de dados históricos (Hanifi et al., 2020).

#### **3.5.2 Detecção de *Outliers***

A detecção de *outliers*, ou valores atípicos, é um processo fundamental em diversas áreas de estudo, incluindo a previsão de energia eólica. *Outliers* são dados que se desviam significativamente dos outros pontos de um conjunto de dados e podem distorcer análises e previsões.

No contexto dos dados de SCADA, que monitoram e controlam operações em turbinas eólicas, a presença de outliers pode levar a previsões imprecisas de produção de energia eólica.

Os outliers nos dados de SCADA geralmente são causados por:

- ▲ Falta de calibração dos sensores: Sensores mal calibrados podem fornecer leituras erradas que se destacam como *outliers*.
- ▲ Degradação dos sensores ao longo do tempo: Sensores que envelhecem ou sofrem desgaste podem começar a fornecer dados imprecisos.
- ▲ Fatores externos inesperados: Condições meteorológicas extremas ou eventos imprevistos podem criar leituras anômalas.

No entanto, diversas técnicas de detecção e eliminação de *outliers* têm sido aplicadas, como algoritmos de pré-processamento, processos gaussianos e *Isolation Forest* (IF). A detecção de *outliers* traz vários benefícios, tais como a melhoria da qualidade dos dados e o aumento da precisão das previsões (Hanifi et al., 2020).

## CASO DE ESTUDO: APLICAÇÃO DO MÉTODO ANN PARA PREVISÃO DE PRODUÇÃO DA ENERGIA EÓLICA

Neste capítulo, é apresentado um caso de estudo para a previsão de produção de energia eólica para um horizonte de 1h. As etapas para a implementação deste estudo estão ilustradas na figura 4.1. Os parâmetros de entrada e saída, incluem dados históricos de Previsão Numérica do Tempo (NWP) e dados de produção de energia provenientes do gerador eólico localizado na Faculdade de Ciências e Tecnologias da Universidade Nova de Lisboa, situada no Monte da Caparica, Almada, Setúbal.




Figura 4.1- Etapas para a implementação do caso de estudo

### 4.1 Escolha e Justificativa do Método

A decisão sobre a escolha do método de previsão mais adequado para a produção de energia eólica é crucial e deve levar em consideração diversos fatores essenciais. Conforme

descrito no capítulo anterior, destacam-se entre esses fatores o horizonte temporal da previsão, a disponibilidade e qualidade dos dados, os recursos computacionais disponíveis e as necessidades específicas para qual se pretende prever a produção de energia elétrica através de recursos eólicos bem como a precisão que o mesmo método apresenta, em comparação com aos outros.

No entanto, a escolha da rede neuronal artificial para previsão a curto prazo da produção de energia eólica do gerador eólico localizado na FCT pode ser justificada tendo em conta esses fatores da seguinte forma:

**Horizonte temporal da previsão:** O método escolhido é conhecido por sua eficácia na previsão de produção de energia eólica desde muito curto até curto prazo devido à sua capacidade de aprender dados complexos e não lineares. Isso a torna uma escolha adequada para previsões em horizontes de tempo de curto prazo.

**Precisão e erros de previsão:** As ANN, têm a capacidade de identificar relações não lineares entre as características de entrada e os dados de saída. Essa característica pode resultar em previsões mais precisas, isto é, com menor margem de erros em comparação com métodos que apresentam características lineares, como ARMA, especialmente em cenários complexos como a produção de energia eólica, onde o vento apresenta características instável ao longo do tempo.

**Disponibilidade e qualidade dos dados:** o método selecionado pode lidar eficientemente com grandes conjuntos de dados e é capaz de aprender rapidamente com as informações passadas (dados históricos) para melhorar a precisão das previsões. Se os dados de entrada forem abundantes e de boa qualidade, as ANN podem aproveitar ao máximo essas informações e apresentarem resultados eficientes.

**Recursos Computacionais:** Os treinos dos métodos baseados em redes neurais artificiais não exigem recursos computacionais elevados em comparação com os métodos físicos e os baseados em series temporais. Isso torna o método selecionado uma escolha prática e eficiente para implementação em cenários onde os recursos computacionais podem ser limitados.

Entretanto, ao considerar esses fatores e as necessidades específicas de previsão da produção de energia elétrica por meio de recursos eólicos, e uma vez que os métodos estatísticos apresentam um melhor desempenho em previsões com poucas horas de avanço, o algoritmo ANN escolhido é o feedforward ou MLP para prever a produção da energia eólica a curto prazo. Embora métodos baseados em modelos físicos, séries temporais, RBFNN e ENN

apresentem suas próprias vantagens, o MLP oferece um equilíbrio ideal entre precisão, eficiência e facilidade de implementação.

## 4.2 Caracterização e Localização do Gerador Eólico

O gerador eólico utilizado para a produção de energia elétrica possui uma potência nominal de 2 kW. A curva característica de potência, fornecida pelo fabricante, está representada na figura 4.2.




Figura 4.2 - Curva característica do gerador eólico modelo FD3.6-2000L.10L (Rogado, 2018)

O gerador eólico está instalado no topo do Edifício X, do Departamento de Eletrotécnica e de Computadores. Este gerador, ilustrado na Figura 4.3, é o componente responsável pela conversão da energia cinética do vento em energia elétrica.



Figura 4.3 - Gerador eólico modelo FD3.6-2000L.10L (Rogado, 2018)

### 4.3 Descrição do Software

Para as simulações realizadas no caso de estudo sobre a previsão da produção de energia eólica, foi utilizado um *software* que permitiu simular uma serie temporal. Este *software* foi escolhido devido à sua simplicidade de utilização e à capacidade de implementar modelos de redes neuronais do tipo MLP com o algoritmo de *backpropagation* de *Levenberg-Marquardt*. As principais funções utilizadas na implementação do modelo foram:

- ▲ *feedforwardnet*: Esta função cria uma rede *feedforward*, permitindo definir a configuração da rede, incluindo o número de camadas ocultas e de neurónios em cada camada escondida.
- ▲ *train*: Função responsável pelo treino da rede, onde os pesos e as constantes são ajustados utilizando o algoritmo de treino.
- ▲ *net* (entradas fornecidas): Que determina as saídas (potências) da rede para as entradas fornecidas (velocidade e direção do vento).

Outro fator a destacar na escolha do software foi a sua capacidade de lidar com grandes volumes de dados, combinada com as suas ferramentas de modelação, o que permitiu construir um modelo mais preciso e eficiente.

As etapas principais do uso do *software* na dissertação incluíram a importação e processamento de dados históricos (velocidade do vento, direção do vento e potência elétrica), o desenvolvimento e treino do modelo com diferentes configurações de redes neurais, a avaliação do desempenho das mesmas com métricas como MAE, RMSE e MAPE, visualização gráfica dos resultados obtidos nas fases de treino, validação e teste.

## 4.4 Pré-Processamento e Tratamento dos Dados

Os dados históricos utilizados para a previsão foram coletados por um medidor meteorológico e de energia localizado na Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa. Esses dados foram obtidos em intervalos de 1 minuto ao longo de 1 ano, inclui informações meteorológicas detalhadas, essenciais para a previsão da produção de energia eólica. As variáveis monitoradas incluem a velocidade e direção do vento, a temperatura, e dados de produção elétrica, entretanto, para previsão da produção de energia, as informações meteorológicas utilizadas como entrada, foram a velocidade e a direção do vento. Para adequar esses dados aos intervalos padronizados, foram calculadas médias das variáveis meteorológicas e de potência em intervalos de 1 hora, isso resultou num conjunto de 8760 amostras.

O conjunto de dados foi coletado do dia 1 de janeiro de 2013, às 12:00 AM, até 31 de dezembro de 2013, às 11:00 PM. A série de dados foi interrompida em 07 de Novembro de 2013, às 06:00 AM, e, a partir desse ponto, foram reservadas 1314 amostras para realização previsões horárias, o que corresponde um período de 7 semanas e 6 dias, finalizado no dia 31 de dezembro de 2013. É necessário mencionar esta divisão foi feita tanto para os dados de entrada (dados meteorológicos) como os de saída (potências).

Entretanto, dado que os parâmetros de entrada e saída totalizam 7446 amostras, foi necessário realizar uma análise estatística e uma representação gráfica antes de proceder às previsões, o tratamento dos dados foi feito com o *software Data Cleaner*, disponível no *software* utilizado, nesta etapa, os dados sofreram um pré-processamento, que constitui numa operação de filtragem, para eliminar valores espúrios. Assim, as figuras abaixo apresentam os gráficos da série temporal da velocidade vento para o período 01 de Janeiro de 2013 à 07 de Novembro de 2013, assim como o gráfico das respetivas potências produzidas.




Figura 4.4 - Dados históricos das amostras da velocidade do vento (m/s)

Os dados estatísticos referentes às amostras da velocidade do vento, apresentados no gráfico acima, estão também ilustrados na tabela a seguir.

Tabela 4.1- Estatísticas Resumidas das Amostras de Velocidade do Vento

| Nº de amostras | Velocidade mínima (m/s) | Velocidade média (m/s) | Velocidade máxima (m/s) | Desvio Padrão (m/s) |
|----------------|-------------------------|------------------------|-------------------------|---------------------|
| 7446           | 0,07                    | 4,98                   | 15,72                   | 2,23                |




Figura 4.5 -Dados Históricos das Amostras da Potência Produzida

E quanto aos dados estatísticos referentes às amostras da Potência produzida, apresentados no gráfico acima, elas estão também ilustradas na tabela a seguir.

Tabela 4.2 - Estatísticas Resumidas das Amostras da Potência Produzida

| Nº de amostras | Potência mínima<br>(W) | Potência média<br>(W) | Potência máxima<br>(W) | Desvio Padrão<br>(W) |
|----------------|------------------------|-----------------------|------------------------|----------------------|
| 7446           | 0                      | 460,52                | 1500                   | 371,62               |

Ao analisar a tabela 4.1 e 4.2, verifica-se uma dispersão das grandezas em relação aos valores médios, sendo o Desvio Padrão a medida estatística que representa essa variabilidade. Portanto, um desvio padrão baixo indica que os dados amostrados estão mais próximos do valor médio, enquanto um desvio padrão alto indica que os dados estão mais afastados da média. No caso da velocidade do vento, o desvio padrão de 2,23 m/s revela uma dispersão quase moderada em torno da média de 2,48 m/s, isso indica variações consistentes nas medições. Já na potência produzida, o desvio padrão de 371,62 W em relação à média de 460,52 W indica uma elevada variabilidade, o que aponta para flutuações significativas na produção, causadas pelas variações consistentes na velocidade do vento.

## 4.5 Implementação do Modelo de Previsão

Para a implementação da rede neuronal escolhida para a previsão da produção de energia eólica, foram realizados os seguintes procedimentos:

O primeiro procedimento consistiu na separação dos dados em dois conjuntos a destacar:

- ▲ O treino da rede neuronal foi feito com 6.132 amostras de velocidade e direção do vento como parâmetros de entrada e o mesmo número de amostras das respectivas potências como dados de saída. Essas amostras foram extraídas da base de dados que compreende o período de 1 de janeiro de 2013 até 13 de setembro de 2013, às 11:00 AM.
- ▲ O conjunto de dados reservado para validação incluiu 1.314 amostras de velocidade e direção do vento como parâmetros de entrada, com as suas respectivas potências como dados de saída. Este conjunto abrangeu o período de 13 de setembro de 2013, às 12:00 PM, até 7 de novembro de 2013, às 5:00 AM.

É importante salientar que a separação dos dados em conjunto de treino e conjunto de validação foi feita com o propósito de evitar o chamado *overfitting*, que ocorre quando o modelo se ajusta tão bem aos dados de treino que perde a capacidade de generalizar para novos dados. Desta maneira, ao reservar um conjunto de validação, garante-se que o modelo é

avaliado em dados não vistos durante o treino, o que ajuda a identificar e mitigar o risco de *overfitting*, e assegurar que o modelo tenha um desempenho robusto em dados reais.

O modelo implementado foi configurado para realizar previsões para a hora seguinte. Essa decisão foi baseada no fato de que a série temporal de velocidade e direção do vento, assim como as respectivas potências, foram organizadas em valores médios horários.

O segundo procedimento consistiu na definição da estrutura da rede neural, que envolveu a escolha da topologia a ser implementada, tipo de função de ativação, a determinação do número de variáveis nas camadas de entrada e de saída, bem como a definição do número de camadas ocultas e da quantidade de neurônios em cada uma delas. Para identificar a configuração mais eficiente, seis diferentes configurações da rede foram treinadas e validadas durante esta fase, com o objetivo de encontrar a estrutura que oferecesse a maior precisão.

O terceiro procedimento abrangeu o treino e a validação da rede, um processo que será detalhado na próxima seção. A validação foi crucial para assegurar que a rede não apenas aprendesse os padrões dos dados de treino, mas também generalizasse bem para novos dados, de modo a minimizar o risco de *overfitting*.

Durante o treino, foi utilizado o algoritmo de treino, responsável pelo ajuste dos pesos da rede. Conforme recomendado pela literatura, a rede foi treinada repetidamente até alcançar o melhor resultado. O treino foi interrompido quando a rede demonstrou uma boa capacidade de generalização e a taxa de erro quadrático médio atingiu um valor suficientemente baixo ou aceitável. Nesta etapa, os pesos foram continuamente ajustados até que se atingisse o ponto ótimo de desempenho. É importante salientar que foram utilizadas as principais métricas de análise de desempenho, como MAE, MSE e MAPE, para comparar as diferentes configurações e identificar o modelo com o melhor desempenho.

O último procedimento envolveu a fase de teste da rede. Nesta etapa, foi utilizado o conjunto de dados previamente reservado, composto por 1.314 amostras, para avaliar o desempenho da rede na previsão da produção de energia eólica. As amostras desta fase de teste cobriram o período de 7 de novembro de 2013, às 6:00 AM, até 31 de dezembro de 2013, às 11:00 PM. Devido à quantidade significativa de amostras, foram selecionados dias específicos para realizar as previsões e verificar a precisão do modelo. O desempenho da rede foi avaliado ao utilizar as três das principais métricas normalmente empregadas para essa finalidade, detalhadas no Capítulo 3.

## 4.6 Treino e Validação para Escolha da Melhor Configuração

Para avançar para a fase de previsão, foi necessário primeiro identificar a configuração com o melhor desempenho. Seis configurações foram testadas para isso: uma estrutura com uma camada oculta contendo 5 neurônios, outra com 10 neurônios e uma terceira com 15 neurônios. Além disso, foram avaliadas configurações com duas camadas ocultas, cada uma com 5 neurônios, 10 neurônios e 15 neurônios, respectivamente.

A rede neuronal foi treinada várias vezes com o objetivo de minimizar o erro médio quadrático. De acordo com a revisão da literatura, recomenda-se que a rede seja treinada pelo menos 10 vezes para obter resultados fiáveis. Assim, todas as configurações foram treinadas até 10 vezes.

Para cada configuração, foi escolhida a função de ativação sigmoide bipolar, devido à sua eficácia no processo de treino e aprendizagem, bem como à sua flexibilidade para ser utilizada em várias camadas da rede neuronal. Quanto ao algoritmo de treino, utilizou-se o algoritmo de *backpropagation* de *Levenberg-Marquardt*.

A seguir são apresentados, de forma detalhada, os resultados obtidos nas fases de treino e validação da rede neuronal, com o objetivo de identificar a melhor configuração. Serão discutidas as métricas de desempenho de cada configuração testada, assim como apresentar estrutura da rede que demonstrou o melhor desempenho ao longo do processo.

Tabela 4.3 - Desempenho das diferentes configurações da camada oculta na fase de treino

| Nº Camada escondida | Nº de Neurónios | MAE (W) | RMSE (W) | MAPE (%) |
|---------------------|-----------------|---------|----------|----------|
| 1                   | 5               | 9,22    | 28,02    | 9,84     |
| 1                   | 10              | 8,03    | 26,52    | 7,92     |
| 1                   | 15              | 8,62    | 26,97    | 8,76     |
| 2                   | [5,5]           | 8,26    | 26,16    | 9,30     |
| 2                   | [10,10]         | 7,96    | 26,51    | 6,80     |
| 2                   | [15,15]         | 8,18    | 26,09    | 7,80     |




Figura 4.6 - Análise Gráfica do Desempenho das Diferentes Configurações da Camada Oculta

Na Tabela 4.3 e na Figura 4.6, são apresentados os resultados obtidos durante o treino das diferentes configurações da camada oculta da rede neuronal, com o objetivo de realizar previsões a curto prazo, isto é, no horizonte de 1h. Foram treinadas seis configurações, durante essa etapa, o número de neurónios e de camadas ocultas foram variados, e avaliadas três métricas de desempenho: MAE, RMSE e MAPE.

Durante o treino da rede neuronal, verificou-se uma tendência de melhoria no desempenho à medida que o número de neurónios nas camadas ocultas aumentava. As configurações com duas camadas ocultas, em particular, demonstraram um desempenho superior em termos de precisão das previsões a curto prazo. Especificamente:

- ▲ Configuração com 1 camada oculta e 5 neurónios: Apresentou um desempenho ligeiramente pior, com um MAE de 9,22W, RMSE de 28,02W e MAPE de 9,84%,
- ▲ Configuração com 1 camada oculta e 10 neurónios: verificou-se uma diminuição dos erros, com MAE de 8,03 W, RMSE de 26,52 W e MAPE de 7,92%.
- ▲ Configuração com 1 camada oculta e 15 neurónios: O desempenho voltou a degradar, com um MAE de 8,62 W, RMSE de 26,97W e MAPE de 8,76%.

Nas configurações com duas camadas ocultas, observou-se os seguintes desempenhos:

- ▲ camadas ocultas, 5 neurónios em cada camada [5,5]: O MAE foi de 8,26W, RMSE de 26,16W e MAPE de 9,30%, a rede voltou a apresentar um baixo desempenho com esta configuração.

- ▲ camadas ocultas, 10 neurónios em cada camada [10,10]: o MAE foi de 7,96W, RMSE de 26,51W e MAPE de 6,80%, nesta configuração a rede apresentou um desempenho relativamente superior.
- ▲ camadas ocultas, 15 neurónios em cada camada [15,15]: Os valores de erro aumentaram ligeiramente, com um MAE de 8,18 W, RMSE de 26,09W e MAPE de 7,80%.

Durante o processo de treino da rede neuronal para encontrar a melhor configuração, a rede foi treinada várias vezes, conforme descrito anteriormente, com o objetivo de identificar a configuração ótima. Após o término do treino, verificou-se que a configuração com 2 camadas ocultas e 10 neurónios em cada camada apresentou o melhor desempenho geral, com um MAPE de 6,80%. De salientar que para comparar os modelos normalmente utiliza-se o erro médio percentual absoluto, pois segundo alguns autores, é o critério recomendado quando se pretende comparar o desempenho do mesmo método.

No entanto, para tomar uma decisão definitiva sobre a escolha da configuração ideal, foi necessário validar a rede, de forma a confirmar se a configuração [10,10] seria realmente a mais adequada para realizar as previsões. A seguir, são apresentados os resultados obtidos na fase de validação.

Tabela 4.4 - Desempenho das Diferentes Configurações da Camada Oculta na Fase de Validação

| Nº de Camada Escondida | Nº de Neurónios | MAE (W) | RMSE (W) | MAPE (%) |
|------------------------|-----------------|---------|----------|----------|
| 1                      | 5               | 8,58    | 24,17    | 7,58     |
| 1                      | 10              | 8,26    | 26,80    | 7,16     |
| 1                      | 15              | 8,49    | 25,87    | 8,55     |
| 2                      | [5,5]           | 8,38    | 28,53    | 10,73    |
| 2                      | [10,10]         | 7,87    | 25,29    | 6,50     |
| 2                      | [15,15]         | 8,58    | 27,27    | 7,06     |




Figura 4.7 - Análise Gráfica do Desempenho das Diferentes Configurações da Camada Oculta

Na Tabela 4.4 e na Figura 4.7, são apresentados os resultados obtidos durante a fase de validação das diferentes configurações da camada oculta da rede neuronal. Tal como na fase de treino, foram validadas seis configurações e avaliadas as métricas de desempenho MAE, RMSE e MAPE. A fase de validação teve como objetivo confirmar a precisão das previsões do modelo, após o treino.

Os resultados indicam que a configuração com 2 camadas ocultas e 10 neurónios em cada camada [10,10] continuou a apresentar o melhor desempenho, com um MAPE de 6,50%, o que validou assim a sua superioridade observada na fase de treino. Como pode ser observado na Tabela 4.4, outras configurações apresentaram desempenhos inferiores em comparação com configuração [10,10].

Sendo assim, para realizar a previsão, optou-se pela rede neuronal do tipo *feedforward* com duas camadas ocultas, cada uma com 10 neurónios, visto que foi a configuração que apresentou os melhores resultados nos testes preliminares realizados com até seis configurações diferentes e cuja estrutura está ilustrada na figura 4.8:




Figura 4.8- Estrutura da Rede Neuronal *Feedforward*

A figura 4.8 ilustra a estrutura da rede neuronal seleccionada para realizar a previsão da produção da energia eólica, a mesma é composta por uma camada de entrada, duas camadas ocultas e uma camada de saída. Na camada de entrada, a rede recebe duas variáveis (velocidade e direção do vento) que serão processadas sequencialmente ao longo das camadas. A primeira camada oculta é constituída por 10 neurónios, cada um dos quais aplica uma soma ponderada dos valores de entrada, ajustada pelos pesos e pelo bias. Em seguida, utiliza-se uma função de ativação do tipo sigmoide bipolar, que introduz não linearidade no modelo e permite à rede aprender padrões mais complexos.

De forma semelhante, a segunda camada oculta, também composta por 10 neurónios, aplica o mesmo processo de ponderação e ativação sobre os resultados obtidos na primeira camada. Por fim, a camada de saída, constituída por um único neurónio, realiza uma nova soma ponderada dos valores provenientes da segunda camada oculta e gera o valor final da previsão. Nesta última camada, a função de ativação é linear, dado que o problema em estudo é de natureza contínua.

A Figura 4.9 apresenta os gráficos de regressão correspondentes às fases de treino e validação para a configuração escolhida, onde foi avaliada a capacidade do modelo em realizar previsão.




Figura 4.9 - Análise de Desempenho do Modelo de Regressão: Comparação entre o Valores Reais e Saídas Previstas na fase de Treino e Validação

Como se pode observar nas figuras acima, o modelo escolhido apresentou um desempenho eficaz tanto na fase de treino como na de validação, com um coeficiente de correlação muito próximo de 1 em ambos os casos. A equação aproximada, na fase de treino e na fase de validação indicou que o modelo tem a capacidade de fazer previsões muito próximas dos valores reais, com um pequeno viés. Embora o modelo escolhido tenda a prever valores ligeiramente acima ou abaixo do alvo, a inclinação da linha próxima de 1 demonstra um bom ajuste global entre as previsões e os dados reais.

Este desempenho sugere uma elevada precisão nas previsões, com uma relação forte entre as previsões do modelo e os valores reais. No entanto, os desvios observados nos pontos fora da linha revelam algumas discrepâncias pontuais, que se tornam mais evidentes na fase de validação. Entretanto, esses desvios podem ser atribuídos à complexidade e variabilidade inerentes à previsão de energia eólica. Como mencionado no estado da arte, a produção de

energia eólica é influenciada por vários fatores, como a velocidade e direção do vento, a temperatura e as condições atmosféricas, que são altamente instáveis e difíceis de prever com precisão.

Os resultados correspondentes aos conjuntos de treino e validação estão apresentados nas Figuras 4.10 e 4.11, com a consideração apenas das 60 amostras, a título de exemplo. Estes resultados permitiram ter uma análise detalhada do desempenho do modelo em ambas as fases, o que mostra como ele se ajusta aos dados de treino e como generaliza para novos dados, ou seja, como realizará a previsão dos dados não vistos anteriormente, na fase de validação.




Figura 4.10 - Treino: Real vs. Previsto




Figura 4.11 - Validação: Real vs. Previsto

A Figura 4.10 mostra a comparação entre os valores reais e os previstos durante o treino do modelo de previsão de potência. Observa-se que as duas curvas (real e previsto) seguem trajetórias semelhantes, portanto isso indica que o modelo captou bem a tendência dos dados.

Já a Figura 4.11 apresenta os resultados da validação do modelo, onde a previsão é comparada com os valores reais em um novo conjunto de dados. Embora haja alguns pequenos desvios, o modelo continua a acompanhar de perto a variação da potência real, o que demonstra uma boa capacidade de generalização da configuração escolhida.

## ANÁLISE DOS RESULTADOS

Neste capítulo, serão analisados os resultados obtidos a partir dos dados meteorológicos reservados para realizar a previsão da produção de energia eólica. Como descrito anteriormente foram reservados um total de 1314 amostras para realizar os testes. Estas amostras correspondem os meses de novembro e dezembro. No entanto, à título de exemplo, foi selecionado períodos específicos para se realizar a previsão nesses meses, para um horizonte temporal de uma hora.

Os períodos selecionados para o mês de novembro foram de 7/11/13 às 6:00 AM até 9/11/13 às 5:00 AM, e de 14/11/13 às 12:00 AM até 15/11/13 às 11:00 PM. Para o mês de dezembro, os períodos escolhidos foram de 1/12/13 às 12:00 AM até 2/12/13 às 11:00 PM, e de 14/12/13 às 12:00 AM até 15/12/13 às 11:00 PM.

Importa referir que cada período utilizado para a previsão corresponde a um total de 48 amostras de dados de entrada e saída. Para os dados de entrada, foram consideradas duas variáveis meteorológicas: a velocidade e a direção do vento. Estas variáveis foram aplicadas na entrada do modelo com o objetivo de estimar a potência elétrica na saída e depois compará-los com os valores reais (medidos), com intuito de avaliar o desempenho do modelo nesta fase. Os critérios de avaliação de desempenho serão os mesmos aplicados na fase de treino e validação. Os resultados dessas previsões serão apresentados a seguir.

### 5.1 Previsão da Produção para o Mês de Novembro

As Tabela 5.1 e 5.2 e as Figura 5.1 e 5.2 ilustram os resultados das previsões obtidas pelo método ANN *feedforward*, composta por duas camadas ocultas e 10 neurónios em cada uma, para os dias 7 e 9 e os dias 14 e 15 de novembro, correspondendo a um período total de 4 dias, 2 em cada período. Em termos de critérios de avaliação, a tabela 5.1 apresenta os índices

calculados para cada instante em que as previsões foram realizadas, fazendo desta feita, uma comparação entre o valor real e o valor previsto.

Tabela 5.1- Resultados da Previsão da Produção para os dias 7 e 9 de Novembro (horizonte de 1h)

| Dados Meteorológicos |                  |             | Potência     |          |          |        |         |
|----------------------|------------------|-------------|--------------|----------|----------|--------|---------|
| Data                 | Velocidade (m/s) | Direção (°) | Prevista (W) | Real (W) | Erro (W) | AE (W) | APE (%) |
| 7/11/13 6:00 AM      | 2,48             | 0,00        | 84,93        | 82,65    | -2,28    | 2,28   | 2,75    |
| 7/11/13 7:00 AM      | 2,28             | 0,00        | 70,78        | 67,96    | -2,83    | 2,83   | 4,16    |
| 7/11/13 8:00 AM      | 2,14             | 0,00        | 58,05        | 58,60    | 0,55     | 0,55   | 0,94    |
| 7/11/13 9:00 AM      | 2,28             | 0,00        | 70,78        | 67,96    | -2,83    | 2,83   | 4,16    |
| 7/11/13 10:00 AM     | 3,45             | 0,00        | 175,31       | 177,51   | 2,20     | 2,20   | 1,24    |
| 7/11/13 11:00 AM     | 3,93             | 0,00        | 239,46       | 239,98   | 0,52     | 0,52   | 0,21    |
| 7/11/13 12:00 PM     | 4,28             | 0,00        | 294,26       | 292,37   | -1,89    | 1,89   | 0,65    |
| 7/11/13 1:00 PM      | 4,41             | 0,00        | 309,47       | 313,16   | 3,69     | 3,69   | 1,18    |
| 7/11/13 2:00 PM      | 4,34             | 0,00        | 294,26       | 301,88   | 7,62     | 7,62   | 2,53    |
| 7/11/13 3:00 PM      | 4,14             | 0,00        | 267,62       | 270,75   | 3,13     | 3,13   | 1,16    |
| 7/11/13 4:00 PM      | 4,21             | 0,00        | 280,34       | 281,45   | 1,11     | 1,11   | 0,39    |
| 7/11/13 5:00 PM      | 3,72             | 0,00        | 211,47       | 211,32   | -0,15    | 0,15   | 0,07    |
| 7/11/13 6:00 PM      | 3,66             | 0,00        | 211,47       | 203,51   | -7,96    | 7,96   | 3,91    |
| 7/11/13 7:00 PM      | 3,86             | 0,00        | 239,46       | 230,19   | -9,27    | 9,27   | 4,03    |
| 7/11/13 8:00 PM      | 4,14             | 0,00        | 267,62       | 270,75   | 3,13     | 3,13   | 1,16    |
| 7/11/13 9:00 PM      | 4,28             | 0,00        | 294,26       | 292,37   | -1,89    | 1,89   | 0,65    |
| 7/11/13 10:00 PM     | 4,34             | 0,00        | 294,26       | 301,88   | 7,62     | 7,62   | 2,53    |
| 7/11/13 11:00 PM     | 4,28             | 0,00        | 294,26       | 292,37   | -1,89    | 1,89   | 0,65    |
| 8/11/13 12:00 AM     | 4,07             | 0,00        | 267,62       | 260,26   | -7,36    | 7,36   | 2,83    |
| 8/11/13 1:00 AM      | 4,14             | 0,00        | 267,62       | 270,75   | 3,13     | 3,13   | 1,16    |
| 8/11/13 2:00 AM      | 3,93             | 0,00        | 239,46       | 239,98   | 0,52     | 0,52   | 0,21    |
| 8/11/13 3:00 AM      | 3,52             | 0,00        | 175,31       | 185,95   | 10,64    | 10,64  | 5,72    |
| 8/11/13 4:00 AM      | 3,93             | 0,00        | 239,46       | 239,98   | 0,52     | 0,52   | 0,21    |
| 8/11/13 5:00 AM      | 4,14             | 0,00        | 267,62       | 270,75   | 3,13     | 3,13   | 1,16    |
| 8/11/13 6:00 AM      | 4,28             | 0,00        | 294,26       | 292,37   | -1,89    | 1,89   | 0,65    |
| 8/11/13 7:00 AM      | 5,45             | 0,00        | 520,42       | 497,07   | -23,35   | 23,35  | 4,70    |
| 8/11/13 8:00 AM      | 6,62             | 0,00        | 722,70       | 715,64   | -7,06    | 7,06   | 0,99    |
| 8/11/13 9:00 AM      | 6,34             | 0,00        | 654,03       | 663,28   | 9,25     | 9,25   | 1,39    |
| 8/11/13 10:00 AM     | 5,45             | 0,00        | 520,42       | 497,07   | -23,35   | 23,35  | 4,70    |
| 8/11/13 11:00 AM     | 6,07             | 0,00        | 616,35       | 613,05   | -3,29    | 3,29   | 0,54    |
| 8/11/13 12:00 PM     | 6,00             | 0,00        | 597,30       | 600,00   | 2,70     | 2,70   | 0,45    |
| 8/11/13 1:00 PM      | 6,21             | 0,00        | 635,07       | 639,10   | 4,03     | 4,03   | 0,63    |
| 8/11/13 2:00 PM      | 6,28             | 0,00        | 654,03       | 652,12   | -1,92    | 1,92   | 0,29    |
| 8/11/13 3:00 PM      | 6,41             | 0,00        | 673,99       | 676,32   | 2,32     | 2,32   | 0,34    |
| 8/11/13 4:00 PM      | 6,48             | 0,00        | 696,37       | 689,38   | -6,98    | 6,98   | 1,01    |
| 8/11/13 5:00 PM      | 5,72             | 0,00        | 523,60       | 547,56   | 23,96    | 23,96  | 4,38    |
| 8/11/13 6:00 PM      | 5,24             | 0,00        | 444,25       | 458,19   | 13,95    | 13,95  | 3,04    |

|                  |      |      |        |        |       |      |      |
|------------------|------|------|--------|--------|-------|------|------|
| 8/11/13 7:00 PM  | 4,48 | 0,00 | 325,01 | 324,63 | -0,39 | 0,39 | 0,12 |
| 8/11/13 8:00 PM  | 4,62 | 0,00 | 340,73 | 348,06 | 7,33  | 7,33 | 2,10 |
| 8/11/13 9:00 PM  | 4,48 | 0,00 | 325,01 | 324,63 | -0,39 | 0,39 | 0,12 |
| 8/11/13 10:00 PM | 4,34 | 0,00 | 294,26 | 301,88 | 7,62  | 7,62 | 2,53 |
| 8/11/13 11:00 PM | 4,41 | 0,00 | 309,47 | 313,16 | 3,69  | 3,69 | 1,18 |
| 9/11/13 12:00 AM | 4,34 | 0,00 | 294,26 | 301,88 | 7,62  | 7,62 | 2,53 |
| 9/11/13 1:00 AM  | 4,41 | 0,00 | 309,47 | 313,16 | 3,69  | 3,69 | 1,18 |
| 9/11/13 2:00 AM  | 3,86 | 0,00 | 239,46 | 230,19 | -9,27 | 9,27 | 4,03 |
| 9/11/13 3:00 AM  | 3,72 | 0,00 | 211,47 | 211,32 | -0,15 | 0,15 | 0,07 |
| 9/11/13 4:00 AM  | 4,07 | 0,00 | 267,62 | 260,26 | -7,36 | 7,36 | 2,83 |
| 9/11/13 5:00 AM  | 4,21 | 0,00 | 280,34 | 281,45 | 1,11  | 1,11 | 0,39 |




Figura 5.1- Previsão da Potência para o dia 7 e 9 de novembro

Como pode ser observado na tabela 5.1, a previsão da potência elétrica variou de forma relativamente precisa em comparação com os valores reais, com pequenas diferenças, como observado no AE e no APE. O AE variou de 0,15 W a 23,35 W e o APE variou de 0,07% a 5,72%. Verifica-se que os erros mais significativos foram observados nas horas de maior variação de velocidade do vento, como em 8/11 às 7:00 AM, onde o erro foi de 23,35 W, que corresponde a 4,70% de APE.

Na figura 5.1, é notável que as linhas, que representam os valores reais e previstos, tendem a seguir trajetórias semelhantes, com pequenas variações. Nos períodos em que a velocidade do vento foi mais constante, as linhas de previsão e de valores reais se aproximam muito, indicando boa precisão do modelo. Já nos momentos em que houve maior variação do

vento, como na manhã de 8 de novembro, as linhas se afastam um pouco mais, o que reflete deste modo os erros mencionados na tabela.

Tabela 5.2 - Resultados da Previsão da Produção para os dias 14 e 15 de Novembro (horizonte de 1h)

| Dados Meteorológicos |                  |             | Potência     |          |          |        |         |
|----------------------|------------------|-------------|--------------|----------|----------|--------|---------|
| Data                 | Velocidade (m/s) | Direção (°) | Prevista (W) | Real (W) | Erro (W) | AE (W) | APE (%) |
| 14/11/13 12:00 AM    | 5,59             | 0,00        | 490,66       | 523,21   | 32,55    | 32,55  | 6,22    |
| 14/11/13 1:00 AM     | 5,45             | 0,00        | 520,42       | 497,07   | -23,35   | 23,35  | 4,70    |
| 14/11/13 2:00 AM     | 5,66             | 0,00        | 523,60       | 536,32   | 12,72    | 12,72  | 2,37    |
| 14/11/13 3:00 AM     | 5,79             | 0,00        | 553,70       | 560,69   | 6,99     | 6,99   | 1,25    |
| 14/11/13 4:00 AM     | 5,79             | 0,00        | 553,70       | 560,69   | 6,99     | 6,99   | 1,25    |
| 14/11/13 5:00 AM     | 5,79             | 0,00        | 553,70       | 560,69   | 6,99     | 6,99   | 1,25    |
| 14/11/13 6:00 AM     | 5,79             | 0,00        | 553,70       | 560,69   | 6,99     | 6,99   | 1,25    |
| 14/11/13 7:00 AM     | 5,86             | 0,00        | 577,05       | 573,81   | -3,24    | 3,24   | 0,56    |
| 14/11/13 8:00 AM     | 5,93             | 0,00        | 577,05       | 586,92   | 9,87     | 9,87   | 1,68    |
| 14/11/13 9:00 AM     | 5,86             | 0,00        | 577,05       | 573,81   | -3,24    | 3,24   | 0,56    |
| 14/11/13 10:00 AM    | 6,21             | 0,00        | 635,07       | 639,10   | 4,03     | 4,03   | 0,63    |
| 14/11/13 11:00 AM    | 6,07             | 0,00        | 616,35       | 613,05   | -3,29    | 3,29   | 0,54    |
| 14/11/13 12:00 PM    | 5,93             | 0,00        | 577,05       | 586,92   | 9,87     | 9,87   | 1,68    |
| 14/11/13 1:00 PM     | 5,66             | 0,00        | 523,60       | 536,32   | 12,72    | 12,72  | 2,37    |
| 14/11/13 2:00 PM     | 5,24             | 0,00        | 444,25       | 458,19   | 13,95    | 13,95  | 3,04    |
| 14/11/13 3:00 PM     | 4,90             | 0,00        | 392,90       | 396,70   | 3,80     | 3,80   | 0,96    |
| 14/11/13 4:00 PM     | 4,83             | 0,00        | 374,81       | 384,34   | 9,53     | 9,53   | 2,48    |
| 14/11/13 5:00 PM     | 5,10             | 0,00        | 427,81       | 432,61   | 4,80     | 4,80   | 1,11    |
| 14/11/13 6:00 PM     | 5,45             | 0,00        | 520,42       | 497,07   | -23,35   | 23,35  | 4,70    |
| 14/11/13 7:00 PM     | 5,79             | 0,00        | 553,70       | 560,69   | 6,99     | 6,99   | 1,25    |
| 14/11/13 8:00 PM     | 6,00             | 0,00        | 597,30       | 600,00   | 2,70     | 2,70   | 0,45    |
| 14/11/13 9:00 PM     | 5,31             | 0,00        | 463,48       | 471,09   | 7,62     | 7,62   | 1,62    |
| 14/11/13 10:00 PM    | 5,17             | 0,00        | 444,25       | 445,36   | 1,11     | 1,11   | 0,25    |
| 14/11/13 11:00 PM    | 5,24             | 0,00        | 444,25       | 458,19   | 13,95    | 13,95  | 3,04    |
| 15/11/13 12:00 AM    | 5,59             | 0,00        | 490,66       | 523,21   | 32,55    | 32,55  | 6,22    |
| 15/11/13 1:00 AM     | 5,10             | 0,00        | 427,81       | 432,61   | 4,80     | 4,80   | 1,11    |
| 15/11/13 2:00 AM     | 4,21             | 0,00        | 280,34       | 281,45   | 1,11     | 1,11   | 0,39    |
| 15/11/13 3:00 AM     | 5,03             | 0,00        | 410,77       | 419,95   | 9,17     | 9,17   | 2,18    |
| 15/11/13 4:00 AM     | 5,59             | 0,00        | 490,66       | 523,21   | 32,55    | 32,55  | 6,22    |
| 15/11/13 5:00 AM     | 5,24             | 0,00        | 444,25       | 458,19   | 13,95    | 13,95  | 3,04    |
| 15/11/13 6:00 AM     | 5,31             | 0,00        | 463,48       | 471,09   | 7,62     | 7,62   | 1,62    |
| 15/11/13 7:00 AM     | 5,10             | 0,00        | 427,81       | 432,61   | 4,80     | 4,80   | 1,11    |
| 15/11/13 8:00 AM     | 5,31             | 0,00        | 463,48       | 471,09   | 7,62     | 7,62   | 1,62    |
| 15/11/13 9:00 AM     | 5,17             | 0,00        | 444,25       | 445,36   | 1,11     | 1,11   | 0,25    |
| 15/11/13 10:00 AM    | 5,38             | 0,00        | 493,53       | 484,06   | -9,47    | 9,47   | 1,96    |
| 15/11/13 11:00 AM    | 5,59             | 0,00        | 490,66       | 523,21   | 32,55    | 32,55  | 6,22    |
| 15/11/13 12:00 PM    | 5,24             | 0,00        | 444,25       | 458,19   | 13,95    | 13,95  | 3,04    |
| 15/11/13 1:00 PM     | 5,66             | 0,00        | 523,60       | 536,32   | 12,72    | 12,72  | 2,37    |

|                   |      |      |        |        |       |      |      |
|-------------------|------|------|--------|--------|-------|------|------|
| 15/11/13 2:00 PM  | 6,62 | 0,00 | 722,70 | 715,64 | -7,06 | 7,06 | 0,99 |
| 15/11/13 3:00 PM  | 7,59 | 0,00 | 908,67 | 908,46 | -0,21 | 0,21 | 0,02 |
| 15/11/13 4:00 PM  | 7,66 | 0,00 | 928,71 | 923,54 | -5,17 | 5,17 | 0,56 |
| 15/11/13 5:00 PM  | 7,59 | 0,00 | 908,67 | 908,46 | -0,21 | 0,21 | 0,02 |
| 15/11/13 6:00 PM  | 7,79 | 0,00 | 949,45 | 952,12 | 2,67  | 2,67 | 0,28 |
| 15/11/13 7:00 PM  | 7,52 | 0,00 | 889,20 | 893,58 | 4,38  | 4,38 | 0,49 |
| 15/11/13 8:00 PM  | 7,72 | 0,00 | 928,71 | 936,64 | 7,92  | 7,92 | 0,85 |
| 15/11/13 9:00 PM  | 7,72 | 0,00 | 928,71 | 936,64 | 7,92  | 7,92 | 0,85 |
| 15/11/13 10:00 PM | 7,10 | 0,00 | 817,68 | 807,94 | -9,73 | 9,73 | 1,20 |
| 15/11/13 11:00 PM | 6,90 | 0,00 | 774,52 | 768,94 | -5,59 | 5,59 | 0,73 |




Figura 5.2 -Previsão da Potência para o dia 14 e 15 de novembro

Similarmente ao primeiro período, como pode ser observado na 5.2, os erros variaram. O AE variou de 0,10 W a 32,55 W, sendo os maiores erros registados nas primeiras horas de 14 de novembro, quando o vento era mais instável. O APE variou de 0,10% a 6,22%, com picos nas horas de maior variação do vento. O erro mais significativo foi verificado em 14/11 às 12:00 AM, com um valor de 32,55 W correspondente 6,22%.

A figura 5.2 segue a mesma lógica do anterior, a previsão segue de perto os valores reais, com pequenas discrepâncias. Novamente, podemos ver que os maiores desvios visíveis correspondem aos períodos de maior variação de vento ou momentos de menor intensidade do vento, como na noite de 14 para 15 de novembro.

Contudo, a maioria das previsões para ambos períodos teve erros percentuais abaixo de 2%, o que indica uma boa precisão do modelo.

Os resultados das métricas de desempenho da previsão da potência para os períodos analisados no mês de novembro estão apresentados na Tabela 5.3. Esses resultados foram avaliados com base nos índices MAE, RMSE e MAPE.

Tabela 5.3 - Resultados dos critérios de avaliação para os dois períodos analisados em Novembro

| Dia     | MAE (W) | RMSE (W) | MAPE (%) |
|---------|---------|----------|----------|
| 7 e 9   | 5,39    | 7,84     | 1,75     |
| 14 e 15 | 9,70    | 12,88    | 1,84     |

As métricas gerais de desempenho foram: MAE de 5,39 W, RMSE de 7,84 W e MAPE de 1,75% nos dias 7 e 9; e MAE de 9,70 W, RMSE de 12,88 W e MAPE de 1,84% nos dias 14 e 15. Observa-se, portanto, que o desempenho nos dias 14 e 15 foi ligeiramente inferior ao do período de 7 a 9, mas ainda dentro de margens aceitáveis, o que demonstra que o modelo manteve sua eficácia.

## 5.2 Previsão da Produção para o Mês de Dezembro

Em relação ao mês de dezembro, foram reservados os dias 1 e 2, bem como os dias 14 e 15, para a realização das previsões. Assim, o período total reservado foi de 4 dias, sendo 2 dias em cada período. Os resultados para este segundo caso estão apresentados a seguir:

Tabela 5.4 - Resultados da Previsão da Produção para os dias 1 e 2 de Dezembro (horizonte de 1h)

| Dados Meteorológicos |                  |             | Potência     |          |          |        |         |
|----------------------|------------------|-------------|--------------|----------|----------|--------|---------|
| Data                 | Velocidade (m/s) | Direção (°) | Prevista (W) | Real (W) | Erro (W) | AE (W) | APE (%) |
| 1/12/13 12:00 AM     | 4,7              | 0,0         | 357,26       | 360,01   | 2,75     | 2,75   | 0,77    |
| 1/12/13 1:00 AM      | 4,8              | 0,0         | 374,81       | 384,34   | 9,53     | 9,53   | 2,48    |
| 1/12/13 2:00 AM      | 5,1              | 0,0         | 427,81       | 432,61   | 4,80     | 4,80   | 1,11    |
| 1/12/13 3:00 AM      | 5,5              | 0,0         | 520,42       | 510,12   | -10,30   | 10,30  | 2,02    |
| 1/12/13 4:00 AM      | 5,7              | 0,0         | 523,60       | 536,32   | 12,72    | 12,72  | 2,37    |
| 1/12/13 5:00 AM      | 5,9              | 0,0         | 577,05       | 573,81   | -3,24    | 3,24   | 0,56    |
| 1/12/13 6:00 AM      | 5,9              | 0,0         | 577,05       | 586,92   | 9,87     | 9,87   | 1,68    |
| 1/12/13 7:00 AM      | 5,8              | 0,0         | 553,70       | 560,69   | 6,99     | 6,99   | 1,25    |
| 1/12/13 8:00 AM      | 5,7              | 0,0         | 523,60       | 547,56   | 23,96    | 23,96  | 4,38    |
| 1/12/13 9:00 AM      | 5,9              | 0,0         | 577,05       | 586,92   | 9,87     | 9,87   | 1,68    |
| 1/12/13 10:00 AM     | 6,8              | 0,0         | 766,16       | 755,49   | -10,67   | 10,67  | 1,41    |
| 1/12/13 11:00 AM     | 6,6              | 0,0         | 722,70       | 715,64   | -7,06    | 7,06   | 0,99    |
| 1/12/13 12:00 PM     | 6,3              | 0,0         | 654,03       | 652,12   | -1,92    | 1,92   | 0,29    |
| 1/12/13 1:00 PM      | 5,8              | 0,0         | 553,70       | 560,69   | 6,99     | 6,99   | 1,25    |

|                  |     |     |        |        |       |       |      |
|------------------|-----|-----|--------|--------|-------|-------|------|
| 1/12/13 2:00 PM  | 5,4 | 0,0 | 493,53 | 484,06 | -9,47 | 9,47  | 1,96 |
| 1/12/13 3:00 PM  | 5,0 | 0,0 | 410,77 | 409,17 | -1,60 | 1,60  | 0,39 |
| 1/12/13 4:00 PM  | 4,6 | 0,0 | 340,73 | 348,06 | 7,33  | 7,33  | 2,10 |
| 1/12/13 5:00 PM  | 4,5 | 0,0 | 325,01 | 324,63 | -0,39 | 0,39  | 0,12 |
| 1/12/13 6:00 PM  | 4,8 | 0,0 | 374,81 | 384,34 | 9,53  | 9,53  | 2,48 |
| 1/12/13 7:00 PM  | 5,0 | 0,0 | 410,77 | 419,95 | 9,17  | 9,17  | 2,18 |
| 1/12/13 8:00 PM  | 5,2 | 0,0 | 444,25 | 445,36 | 1,11  | 1,11  | 0,25 |
| 1/12/13 9:00 PM  | 5,0 | 0,0 | 410,77 | 409,17 | -1,60 | 1,60  | 0,39 |
| 1/12/13 10:00 PM | 4,7 | 0,0 | 357,26 | 360,01 | 2,75  | 2,75  | 0,77 |
| 1/12/13 11:00 PM | 4,4 | 0,0 | 309,47 | 313,16 | 3,69  | 3,69  | 1,18 |
| 2/12/13 12:00 AM | 4,1 | 0,0 | 267,62 | 270,75 | 3,13  | 3,13  | 1,16 |
| 2/12/13 1:00 AM  | 4,1 | 0,0 | 267,62 | 260,26 | -7,36 | 7,36  | 2,83 |
| 2/12/13 2:00 AM  | 4,1 | 0,0 | 267,62 | 260,26 | -7,36 | 7,36  | 2,83 |
| 2/12/13 3:00 AM  | 4,1 | 0,0 | 267,62 | 270,75 | 3,13  | 3,13  | 1,16 |
| 2/12/13 4:00 AM  | 4,2 | 0,0 | 280,34 | 281,45 | 1,11  | 1,11  | 0,39 |
| 2/12/13 5:00 AM  | 4,3 | 0,0 | 294,26 | 292,37 | -1,89 | 1,89  | 0,65 |
| 2/12/13 6:00 AM  | 4,4 | 0,0 | 309,47 | 313,16 | 3,69  | 3,69  | 1,18 |
| 2/12/13 7:00 AM  | 4,5 | 0,0 | 325,01 | 324,63 | -0,39 | 0,39  | 0,12 |
| 2/12/13 8:00 AM  | 4,5 | 0,0 | 325,01 | 324,63 | -0,39 | 0,39  | 0,12 |
| 2/12/13 9:00 AM  | 4,8 | 0,0 | 374,81 | 372,11 | -2,70 | 2,70  | 0,72 |
| 2/12/13 10:00 AM | 4,4 | 0,0 | 309,47 | 313,16 | 3,69  | 3,69  | 1,18 |
| 2/12/13 11:00 AM | 4,2 | 0,0 | 280,34 | 281,45 | 1,11  | 1,11  | 0,39 |
| 2/12/13 12:00 PM | 4,1 | 0,0 | 267,62 | 260,26 | -7,36 | 7,36  | 2,83 |
| 2/12/13 1:00 PM  | 3,7 | 0,0 | 211,47 | 211,32 | -0,15 | 0,15  | 0,07 |
| 2/12/13 2:00 PM  | 3,3 | 0,0 | 151,04 | 161,29 | 10,25 | 10,25 | 6,35 |
| 2/12/13 3:00 PM  | 3,0 | 0,0 | 125,54 | 131,48 | 5,93  | 5,93  | 4,51 |
| 2/12/13 4:00 PM  | 2,6 | 0,0 | 92,55  | 88,17  | -4,38 | 4,38  | 4,96 |
| 2/12/13 5:00 PM  | 2,5 | 0,0 | 84,93  | 82,65  | -2,28 | 2,28  | 2,75 |
| 2/12/13 6:00 PM  | 2,8 | 0,0 | 108,71 | 105,93 | -2,78 | 2,78  | 2,63 |
| 2/12/13 7:00 PM  | 2,9 | 0,0 | 117,10 | 118,79 | 1,69  | 1,69  | 1,42 |
| 2/12/13 8:00 PM  | 3,2 | 0,0 | 142,39 | 153,51 | 11,12 | 11,12 | 7,25 |
| 2/12/13 9:00 PM  | 3,7 | 0,0 | 211,47 | 203,51 | -7,96 | 7,96  | 3,91 |
| 2/12/13 10:00 PM | 4,1 | 0,0 | 267,62 | 260,26 | -7,36 | 7,36  | 2,83 |
| 2/12/13 11:00 PM | 4,1 | 0,0 | 267,62 | 270,75 | 3,13  | 3,13  | 1,16 |




Figura 5.3 - Previsão da Potência para o dia 1 e 2 de Dezembro

Conforme observado na Tabela 5.4, no mês de dezembro verificou-se também um desvio entre os valores reais e previstos, tal como descrito na primeira análise. Este desvio ocorreu em momentos de maior variabilidade do vento. O AE variou entre 0,10 W (no dia 2/12 às 5:00) e 23,96 W (no dia 1/12 às 8:00). Os maiores erros absolutos foram registrados, em particular, no início da manhã de 1 de dezembro. O APE variou entre 0,10% e 6,35%, com picos observados durante períodos de maior instabilidade do vento, como no dia 1/12 às 14:00 (6,35%) e às 8:00 (4,38%). A figura 5.3 para o início de dezembro mostra uma previsão bastante próxima da realidade. A discrepância mais significativa verificou-se no dia 1/12 às 8:00.

Tabela 5.5 - Resultados da Previsão da Produção para os dias 14 e 15 de Dezembro (horizonte de 1h)

| Dados Meteorológicos |                  |             | Potência     |          |          |        |         |
|----------------------|------------------|-------------|--------------|----------|----------|--------|---------|
| Data                 | Velocidade (m/s) | Direção (°) | Prevista (W) | Real (W) | Erro (W) | AE (W) | APE (%) |
| 14/12/13 12:00 AM    | 2,4              | 14,9        | 78,49        | 77,33    | -1,16    | 1,16   | 1,51    |
| 14/12/13 1:00 AM     | 3,5              | 15,1        | 196,06       | 177,51   | -18,55   | 18,55  | 10,45   |
| 14/12/13 2:00 AM     | 4,2              | 15,2        | 280,54       | 281,45   | 0,91     | 0,91   | 0,32    |
| 14/12/13 3:00 AM     | 4,5              | 15,2        | 328,90       | 324,63   | -4,27    | 4,27   | 1,32    |
| 14/12/13 4:00 AM     | 4,7              | 15,3        | 370,12       | 360,01   | -10,11   | 10,11  | 2,81    |
| 14/12/13 5:00 AM     | 4,5              | 15,3        | 328,94       | 324,63   | -4,31    | 4,31   | 1,33    |
| 14/12/13 6:00 AM     | 4,4              | 15,4        | 310,70       | 313,16   | 2,46     | 2,46   | 0,79    |
| 14/12/13 7:00 AM     | 4,3              | 15,4        | 294,55       | 292,37   | -2,18    | 2,18   | 0,75    |
| 14/12/13 8:00 AM     | 4,3              | 15,3        | 294,48       | 301,88   | 7,41     | 7,41   | 2,45    |
| 14/12/13 9:00 AM     | 4,8              | 15,3        | 390,73       | 372,11   | -18,63   | 18,63  | 5,01    |
| 14/12/13 10:00 AM    | 4,9              | 15,3        | 409,67       | 396,70   | -12,97   | 12,97  | 3,27    |

|                   |     |      |        |        |        |       |       |
|-------------------|-----|------|--------|--------|--------|-------|-------|
| 14/12/13 11:00 AM | 4,8 | 15,9 | 390,09 | 372,11 | -17,98 | 17,98 | 4,83  |
| 14/12/13 12:00 PM | 4,3 | 16,0 | 295,00 | 301,88 | 6,88   | 6,88  | 2,28  |
| 14/12/13 1:00 PM  | 3,5 | 15,8 | 197,06 | 177,51 | -19,55 | 19,55 | 11,01 |
| 14/12/13 2:00 PM  | 3,2 | 15,9 | 150,75 | 153,51 | 2,77   | 2,77  | 1,80  |
| 14/12/13 3:00 PM  | 3,0 | 15,9 | 129,67 | 125,53 | -4,14  | 4,14  | 3,29  |
| 14/12/13 4:00 PM  | 1,6 | 15,6 | 31,63  | 28,98  | -2,65  | 2,65  | 9,16  |
| 14/12/13 5:00 PM  | 1,7 | 15,6 | 36,51  | 32,14  | -4,38  | 4,38  | 13,62 |
| 14/12/13 6:00 PM  | 1,8 | 15,6 | 41,64  | 38,47  | -3,17  | 3,17  | 8,24  |
| 14/12/13 7:00 PM  | 1,8 | 15,5 | 41,64  | 38,47  | -3,17  | 3,17  | 8,23  |
| 14/12/13 8:00 PM  | 2,1 | 15,0 | 58,59  | 54,21  | -4,38  | 4,38  | 8,08  |
| 14/12/13 9:00 PM  | 2,3 | 13,9 | 71,46  | 72,20  | 0,74   | 0,74  | 1,03  |
| 14/12/13 10:00 PM | 2,6 | 13,7 | 93,80  | 88,17  | -5,62  | 5,62  | 6,38  |
| 14/12/13 11:00 PM | 2,8 | 13,7 | 110,86 | 112,26 | 1,40   | 1,40  | 1,24  |
| 15/12/13 12:00 AM | 3,0 | 14,0 | 129,57 | 125,53 | -4,04  | 4,04  | 3,22  |
| 15/12/13 1:00 AM  | 2,9 | 13,7 | 120,01 | 118,79 | -1,22  | 1,22  | 1,03  |
| 15/12/13 2:00 AM  | 3,1 | 13,3 | 139,44 | 138,61 | -0,83  | 0,83  | 0,60  |
| 15/12/13 3:00 AM  | 3,1 | 13,3 | 139,44 | 138,61 | -0,83  | 0,83  | 0,60  |
| 15/12/13 4:00 AM  | 2,8 | 13,3 | 110,86 | 112,26 | 1,40   | 1,40  | 1,25  |
| 15/12/13 5:00 AM  | 2,6 | 13,7 | 93,80  | 93,89  | 0,10   | 0,10  | 0,10  |
| 15/12/13 6:00 AM  | 2,7 | 14,3 | 102,11 | 99,81  | -2,30  | 2,30  | 2,31  |
| 15/12/13 7:00 AM  | 2,8 | 14,4 | 110,86 | 105,93 | -4,93  | 4,93  | 4,65  |
| 15/12/13 8:00 AM  | 2,9 | 14,6 | 120,02 | 118,79 | -1,23  | 1,23  | 1,04  |
| 15/12/13 9:00 AM  | 3,2 | 14,9 | 150,41 | 153,51 | 3,10   | 3,10  | 2,02  |
| 15/12/13 10:00 AM | 2,7 | 15,4 | 102,10 | 99,81  | -2,29  | 2,29  | 2,30  |
| 15/12/13 11:00 AM | 2,5 | 15,8 | 85,93  | 82,65  | -3,28  | 3,28  | 3,97  |
| 15/12/13 12:00 PM | 2,5 | 15,8 | 85,93  | 82,65  | -3,28  | 3,28  | 3,97  |
| 15/12/13 1:00 PM  | 2,6 | 15,7 | 93,79  | 88,17  | -5,62  | 5,62  | 6,38  |
| 15/12/13 2:00 PM  | 2,3 | 15,6 | 71,49  | 72,20  | 0,71   | 0,71  | 0,98  |
| 15/12/13 3:00 PM  | 1,7 | 15,5 | 36,51  | 32,14  | -4,37  | 4,37  | 13,61 |
| 15/12/13 4:00 PM  | 0,8 | 15,4 | 3,29   | 4,15   | 0,86   | 0,86  | 20,67 |
| 15/12/13 5:00 PM  | 0,3 | 15,3 | 1,53   | 7,86   | 6,34   | 6,34  | 80,56 |
| 15/12/13 6:00 PM  | 1,1 | 15,1 | 11,24  | 11,58  | 0,35   | 0,35  | 3,00  |
| 15/12/13 7:00 PM  | 1,7 | 14,9 | 36,50  | 32,14  | -4,36  | 4,36  | 13,57 |
| 15/12/13 8:00 PM  | 1,8 | 14,9 | 41,62  | 38,47  | -3,15  | 3,15  | 8,20  |
| 15/12/13 9:00 PM  | 2,0 | 14,9 | 52,65  | 50,00  | -2,65  | 2,65  | 5,30  |
| 15/12/13 10:00 PM | 2,0 | 14,9 | 52,65  | 50,00  | -2,65  | 2,65  | 5,30  |
| 15/12/13 11:00 PM | 2,1 | 14,9 | 58,59  | 58,60  | 0,02   | 0,02  | 0,03  |




Figura 5.4 - Previsão da Potência para o dia 14 e 15 de Dezembro

Por fim, para os dias 14 e 15 o AE variou de 0,02 W (15/12 às 11:00 PM) a 32,55 W (14/12 às 12:00 AM), sendo este o maior erro absoluto observado durante o período. Já o APE variou de 0,03% (15/12 às 11:00 PM) a 80,56% (15/12 às 5:00 PM), com o maior erro percentual registrado em momentos de vento muito fraco, como no final da tarde de 15 de dezembro.

Relativamente aos critérios de avaliação aplicados aos dois períodos de previsão no mês de dezembro, a Tabela 5.6 apresenta os índices calculados para os dias selecionados.

Tabela 5.6 - Resultados dos critérios de avaliação para os dois períodos analisados em Dezembro

| Dia     | MAE (W) | RMSE (W) | MAPE (%) |
|---------|---------|----------|----------|
| 1 e 2   | 5,58    | 7,11     | 1,82     |
| 14 e 15 | 4,58    | 6,72     | 6,12     |

Como era esperado, os resultados obtidos mantêm-se dentro de uma margem de erro aceitável, com um MAPE de 1,82% para os dias 1 e 2 de dezembro, e um MAPE de 6,12% para os dias 14 e 15. Estes valores indicam que o desempenho do modelo foi significativamente superior nos dias 1 e 2, quando comparado com os dias 14 e 15.

Deste modo, com base nos resultados apresentados, é possível verificar que, em ambos os meses analisados, a utilização de redes neurais artificiais para a previsão da produção de energia eólica mostrou-se viável. O modelo demonstrou tempos de processamento relativamente curtos e uma elevada precisão, aproximando-se bastante dos valores reais observado.

## CONCLUSÕES E RECOMENDAÇÕES

### 6.1 Conclusões

A transição energética para fontes de energias renováveis tem aumentado significativamente o interesse pela energia eólica, uma das opções mais relevantes para a geração de energia elétrica livre de emissões de CO<sub>2</sub>. No entanto, a natureza estocástica do vento tem apresentado desafios consideráveis para a previsão precisa da produção de energia eólica. Neste contexto, a presente dissertação teve como objetivo abordar detalhadamente os principais métodos utilizados para prever a produção da energia elétrica a partir da energia eólica, destacar as vantagens e desvantagens de cada modelo em relação aos outros e o horizonte temporal na qual cada modelo é aplicado. Avaliou-se o desempenho desses métodos através das principais métricas de análise, nomeadamente MAE, RMSE e MAPE. Por fim, foi selecionado um modelo para realizar a simulação da previsão de produção num gerador eólico localizado na Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa.

Foram analisados diferentes métodos e os procedimentos que cada um utiliza para realizar a previsão, desde modelos físicos baseados em Previsão Numérica do Tempo, geralmente utilizados para previsões de longo prazo, até métodos estatísticos, como os modelos autorregressivos de média móvel baseados em séries temporais, e técnicas de inteligência artificial, como as redes neurais artificiais, estas técnicas são amplamente aplicadas para previsões de muito curto, curto e médio prazo, conforme as especificidades da previsão. Os modelos híbridos também foram descritos e, de acordo com a revisão bibliográfica, verificou-se que essa abordagem tende a se destacar como uma solução mais eficaz em termos de precisão, especialmente para previsões a muito curto e curto prazo. Estes modelos combinam abordagens físicas, estatísticas e técnicas de aprendizagem profunda, como o *deep learning*. Verificou-

se que as técnicas de inteligência artificial, nomeadamente as redes neuronais artificiais, têm ganho destaque pela sua capacidade de captar padrões complexos nos dados e no surgimento de diferentes algoritmos de previsão, o que resultou numa elevada capacidade deste modelo em realizar previsões com precisão. Com base nisto, para o caso de estudo, foi selecionada uma Rede Neuronal Artificial do tipo *feedforward*, com duas camadas ocultas e 10 neurónios em cada, para prever a produção de energia eólica a curto prazo. A escolha desta configuração foi feita após vários testes preliminares, nos quais os resultados demonstraram que essa configuração apresentou um desempenho superior em termos de precisão e uma menor margem de erro em comparação com outras configurações.

Os dados históricos foram utilizados para treinar e validar o modelo de previsão. Foram avaliadas seis configurações da rede neuronal, comparadas com base no Erro Percentual Médio Absoluto durante as fases de treino e validação. O MAPE foi selecionado como métrica principal devido à sua capacidade de expressar o erro de forma percentual, e permite realizar uma comparação eficaz entre previsões, independentemente da escala dos dados. Esta métrica ofereceu uma interpretação clara da precisão do modelo, uma vez que indica a média do erro em relação aos valores reais, o que tornou as comparações mais acessíveis e significativas.

Durante a fase do processo preliminares, a configuração com uma camada oculta e 5 neurónios obteve um MAPE de 9,84% no treino e 7,58% na validação. Quando o número de neurónios foi aumentado para 10, o MAPE reduziu para 7,92% no treino e 7,16% na validação. A configuração com 15 neurónios numa camada apresentou um MAPE de 8,62% no treino e 8,55% na validação. Por outro lado, a configuração com duas camadas ocultas e 5 neurónios em cada camada aumentou o MAPE para 9,30% no treino e 10,73% na validação. A configuração com duas camadas ocultas e 10 neurónios em cada alcançou os melhores resultados, com um MAPE de 6,80% no treino e 6,50% na validação. Finalmente, a configuração com duas camadas ocultas e 15 neurónios em cada camada obteve um desempenho razoável, com um MAPE de 7,80% no treino e 7,06% na validação. Durante estas duas fases, a rede foi treinada várias diversas vezes e depois de várias tentativas de análise de erro, a configuração com duas camadas ocultas com 10 neurónios em cada camada foi selecionado para fazer os testes da rede neuronal.

Os resultados apresentados na fase de teste (simulação da previsão) demonstraram que o modelo de redes neuronais artificiais foi eficaz na previsão da produção de energia eólica para um horizonte temporal de 1 hora, nos dois meses analisados. Ao ser utilizado dados meteorológicos históricos, o modelo conseguiu estimar a produção de forma precisa na maioria

dos casos, com erros dentro de margens aceitáveis. Em particular, nos dias 7 e 9 de novembro, o MAPE foi de 1,75%, o que reflete uma elevada precisão. Nos dias 14 e 15 de ambos os meses, o modelo registou um MAPE superior, com valores de 1,84% em novembro e 6,12% em dezembro, isso ocorreu devido à maior instabilidade das condições meteorológicas verificado nesses períodos.

Apesar de uma ligeira redução na precisão em períodos de maior variabilidade do vento, o modelo mostrou-se consistente e eficaz no horizonte de previsão de 1 hora, portanto, isso reafirmou a capacidade das ANN em lidar com a variabilidade e a não linearidade dos dados meteorológicos, como velocidade e direção do vento, tornando assim um método eficiente para realizar previsões a curto prazo.

Entretanto, de acordo com alguns autores, a ligeira redução na precisão verificado no período de maior instabilidade do vento pode ser mitigado com a inclusão de mais variáveis na entrada do modelo, de forma que o valor previsto se aproxime ainda mais do valor real observado. Na base de dados utilizada no caso de estudo, os dados históricos de temperatura e potência poderiam ter sido considerados como variáveis de entrada. Contudo, considerou-se desnecessária a inclusão destas duas variáveis, pois o modelo apresentou excelente desempenho na fase de treino e validação e também por motivos de computacionais. Se tivessem sido consideradas, possivelmente teriam contribuído para a redução das perdas de precisão.

Assim, a inclusão de mais variáveis meteorológicas ou outras informações adicionais aumentaria significativamente a precisão do modelo de rede neuronal em determinados casos. No entanto, isso teria impactado no tempo de processamento, uma vez que o modelo precisaria lidar com um volume maior de dados e padrões. Portanto, achou-se necessário equilibrar a precisão desejada com o recurso computacional disponíveis.

Em suma, a pesquisa e o desenvolvimento de métodos de previsão de alta precisão são essenciais para enfrentar os desafios associados à intermitência da energia da produção da energia eólica e garantir um fornecimento estável de energia elétrica. Este estudo contribuiu para o entendimento do uso de técnicas de redes neurais artificiais na previsão de energia eólica e abre caminho para futuros trabalhos que possam investigar outros métodos mais avançados, como os modelos híbridos para estimar a produção eólico com alta precisão.

## 6.2 Recomendações

Para trabalhos futuros, gostaria de propor algumas considerações a ter em conta:

1. Ajustar a configuração da rede neuronal com outras configurações que não foram abordadas nesta dissertação, como a variação no número de camadas ou de neurónios, e testar diferentes funções de ativação para identificar possíveis configurações que melhorem o desempenho do modelo.

2. Testar o método em ambientes operacionais reais, aplicá-lo em parques eólicos em funcionamento para verificar a sua viabilidade prática e ajustá-lo às necessidades do sector energético. Isto permitirá avaliar o desempenho do modelo em cenários do mundo real e garantir a sua eficácia em condições operacionais.

3. Aplicar o modelo em diferentes regiões geográficas para validar a sua generalização em regiões com características de vento distintas, como áreas costeiras ou montanhosas, de forma a verificar o seu desempenho em diferentes contextos climáticos e topográficos.

4. Incluir mais variáveis no modelo, como temperatura, pressão atmosférica, humidade e densidade do ar, além de dados históricos de produção de energia, como parâmetros de entrada, para aumentar a precisão das previsões.

5. Explorar métodos híbridos mais profundos que combinem abordagens físicas e estatísticas com técnicas avançadas de redes neuronais artificiais, como as *deep learning*, para melhorar a precisão e a robustez dos modelos de previsão.

## BIBLIOGRAFIA

- Abisoye, B. O., Sun, Y., & Zenghui, W. (2024). A survey of artificial intelligence methods for renewable energy forecasting: Methodologies and insights. *Renewable Energy Focus*, 48, 100529. <https://doi.org/10.1016/j.ref.2023.100529>
- Aggarwal, S. K., Aggarwal, S. K., & Gupta, M. (2013). Wind Power Forecasting: A Review of Statistical Models Wind Power Forecasting: A Review of Statistical Models Wind Power Forecasting. In *International Journal of Energy Science (IJES)* (Vol. 3, Issue 1). [www.ijesci.org/](http://www.ijesci.org/)
- Al-Yahyai, S., Charabi, Y., & Gastli, A. (2010). Review of the use of numerical weather prediction (NWP) models for wind energy assessment. In *Renewable and Sustainable Energy Reviews* (Vol. 14, Issue 9, pp. 3192–3198). <https://doi.org/10.1016/j.rser.2010.07.001>
- APA. (2023). *Relatório do estado Do ambiente 2022/2023*. <https://rea.apambiente.pt>
- Arslan Tuncar, E., Sağlam, Ş., & Oral, B. (2024). A review of short-term wind power generation forecasting methods in recent technological trends. In *Energy Reports* (Vol. 12, pp. 197–209). Elsevier Ltd. <https://doi.org/10.1016/j.egy.2024.06.006>
- Bilal, B., Ndongo, M., Kebe, C. M. F., Ndiaye, P. A., Sambou, V., Adjallah, K. H., & Sava, A. (2018). *Wind Turbine Power Output Prediction Model Design Based on Artificial Neural Networks and Climatic Spatiotemporal Data*.
- Burton, T., Jenkins, N., Sharpe, D., & Bossanyi, E. (2001). *WIND ENERGY HANDBOOK* (Vol. 2). [www.wiley.com](http://www.wiley.com)
- Capitão, M. (2010). *Previsão de vento baseado em Técnicas de Data Mining*. Instituto Superior de Engenharia do Porto.

- Carolin Mabel, M., & Fernandez, E. (2008). Analysis of wind power generation and prediction using ANN: A case study. *Renewable Energy*, 33(5), 986–992. <https://doi.org/10.1016/j.renene.2007.06.013>
- Castro, R. (2018). *Uma Introdução às Energias Renováveis: Eólica, Fotovoltaica e Mini-Hídrica* (IST Press, Ed.; 3ª Edição).
- Catalão, J. P. S., Pousinho, H. M. I., & Mendes, V. M. F. (2011). Hybrid wavelet-PSO-ANFIS approach for short-term wind power forecasting in Portugal. *IEEE Transactions on Sustainable Energy*, 2(1), 50–59. <https://doi.org/10.1109/TSTE.2010.2076359>
- Chang, W. (2013). Application of Back Propagation Neural Network for Wind Power Generation Forecasting. *International Journal of Digital Content Technology and Its Applications*, 7(4), 502–509. <https://doi.org/10.4156/JDCTA.VOL7.ISSUE4.61>
- Chen, Q., & Folly, K. A. (2018). Wind Power Forecasting. *IFAC-PapersOnLine*, 51(28), 414–419. <https://doi.org/10.1016/j.ifacol.2018.11.738>
- Costa, P. (2004). *Atlas do Potencial Eólico para Portugal Continental* [Universidade de Lisboa]. <https://www.researchgate.net/publication/259620814>
- De Felice, M., Alessandri, A., & Ruti, P. M. (2013). Electricity demand forecasting over Italy: Potential benefits using numerical weather prediction models. *Electric Power Systems Research*, 104, 71–79. <https://doi.org/10.1016/j.epsr.2013.06.004>
- De Giorgi, M. G., Ficarella, A., & Tarantino, M. (2011). Assessment of the benefits of numerical weather predictions in wind power forecasting based on statistical methods. *Energy*, 36(7), 3968–3978. <https://doi.org/10.1016/j.energy.2011.05.006>
- DGEG. (2024). *Estatísticas rápidas das renováveis*. [www.dgeg.gov.pt](http://www.dgeg.gov.pt)
- Durán, M. J., Cros, D., & Riquelme, J. (2007). Short-Term Wind Power Forecast Based on ARX Models. *Journal of Energy Engineering*, 133(3), 172–180. [https://doi.org/10.1061/\(asce\)0733-9402\(2007\)133:3\(172\)](https://doi.org/10.1061/(asce)0733-9402(2007)133:3(172))
- Dutta, S., Li, Y., Venkataraman, A., Costa, L. M., Jiang, T., Plana, R., Tordjman, P., Choo, F. H., Foo, C. F., & Puttgen, H. B. (2017). Load and Renewable Energy Forecasting for a Microgrid using Persistence Technique. *Energy Procedia*, 143, 617–622. <https://doi.org/10.1016/j.egypro.2017.12.736>
- Enevoldsen, P., Permien, F. H., Bakhtaoui, I., Krauland, A. K. von, Jacobson, M. Z., Xydis, G., Sovacool, B. K., Valentine, S. V., Luecht, D., & Oxley, G. (2019). How much wind power potential does europe have? Examining european wind power potential with

- an enhanced socio-technical atlas. *Energy Policy*, 132, 1092–1100. <https://doi.org/10.1016/j.enpol.2019.06.064>
- Firat, U., Engin, S. N., Saraclar, M., & Ertuzun, A. B. (2010). Wind speed forecasting based on second order blind identification and autoregressive model. *Proceedings - 9th International Conference on Machine Learning and Applications, ICMLA 2010*, 686–691. <https://doi.org/10.1109/ICMLA.2010.106>
- Gallego, C., Pinson, P., Madsen, H., Costa, A., & Cuerva, A. (2011). Influence of local wind speed and direction on wind power dynamics - Application to offshore very short-term forecasting. *Applied Energy*, 88(11), 4087–4096. <https://doi.org/10.1016/j.apenergy.2011.04.051>
- Hanifi, S., Liu, X., Lin, Z., & Lotfian, S. (2020). A Critical Review of Wind Power Forecasting Methods-Past, Present and Future. In *Energies* (Vol. 13, Issue 15). MDPI AG. <https://doi.org/10.3390/en13153764>
- Hong, Y. Y., & Rioflorido, C. L. P. P. (2019). A hybrid deep learning-based neural network for 24-h ahead wind power forecasting. *Applied Energy*, 250, 530–539. <https://doi.org/10.1016/j.apenergy.2019.05.044>
- Jyothi, M. N., & Rao, P. V. R. (2016). *Very-Short Term Wind Power Forecasting through Adaptive Wavelet Neural Network*.
- Khodayar, M., Saffari, M., Williams, M., & Jalali, S. M. J. (2022). Interval deep learning architecture with rough pattern recognition and fuzzy inference for short-term wind speed forecasting. *Energy*, 254. <https://doi.org/10.1016/j.energy.2022.124143>
- Koehler, N. (2021). *MÉTODOS DE PREVISÃO DA PRODUÇÃO RENOVÁVEL E O MERCADO DIÁRIO DE ENERGIA ELÉTRICA*. NOVA SCHOOL OF SCIENCE AND TECHNOLOGY.
- Lange, M., Focken, U., & Waldl, H.-P. (2001). *Previento-A Wind Power Prediction System with an Innovative Upscaling Algorithm*. [www.physik.uni-oldenburg.de/ehf](http://www.physik.uni-oldenburg.de/ehf)
- Lazić, L., Pejanović, G., Živković, M., & Ilić, L. (2014). Improved wind forecasts for wind power generation using the Eta model and MOS (Model Output Statistics) method. *Energy*, 73, 567–574. <https://doi.org/10.1016/j.energy.2014.06.056>
- Lei, M., Shiyan, L., Chuanwen, J., Hongling, L., & Yan, Z. (2009). A review on the forecasting of wind speed and generated power. In *Renewable and Sustainable Energy Reviews* (Vol. 13, Issue 4, pp. 915–920). <https://doi.org/10.1016/j.rser.2008.02.002>

- Lima, J. M., Guetter, A. K., Freitas, S. R., Panetta, J., & de Mattos, J. G. Z. (2017). A Meteorological–Statistic Model for Short-Term Wind Power Forecasting. *Journal of Control, Automation and Electrical Systems*, 28(5), 679–691. <https://doi.org/10.1007/s40313-017-0329-8>
- Lin, Z., Liu, X., & Collu, M. (2020). Wind power prediction based on high-frequency SCADA data along with isolation forest and deep learning neural networks. *International Journal of Electrical Power and Energy Systems*, 118. <https://doi.org/10.1016/j.ijepes.2020.105835>
- Lipu, M. S. H., Miah, M. S., Hannan, M. A., Hussain, A., Sarker, M. R., Ayob, A., Saad, M. H. M., & Mahmud, M. S. (2021). Artificial Intelligence Based Hybrid Forecasting Approaches for Wind Power Generation: Progress, Challenges and Prospects. *IEEE Access*, 9, 102460–102489. <https://doi.org/10.1109/ACCESS.2021.3097102>
- Manwell, J. F., McGowan, J. G., & Rogers, A. L. (2010). *Wind Energy Explained: Theory, Design and Application*.
- Monteiro, C., Bessa, R., Botterud, A., Wang, J., & Conzelmann, G. (2009). *Wind Power Forecasting: State-of-the-Art*. [www.anl.gov](http://www.anl.gov).
- Piotrowski, P., Rutyna, I., Baczyński, D., & Kopyt, M. (2022). Evaluation Metrics for Wind Power Forecasts: A Comprehensive Review and Statistical Analysis of Errors. In *Energies* (Vol. 15, Issue 24). MDPI. <https://doi.org/10.3390/en15249657>
- Ribeiro, M. H. D. M., da Silva, R. G., Moreno, S. R., Mariani, V. C., & Coelho, L. dos S. (2022). Efficient bootstrap stacking ensemble learning model applied to wind power generation forecasting. *International Journal of Electrical Power and Energy Systems*, 136. <https://doi.org/10.1016/j.ijepes.2021.107712>
- Rodríguez, F., Florez-Tapia, A. M., Fontán, L., & Galarza, A. (2020). Very short-term wind power density forecasting through artificial neural networks for microgrid control. *Renewable Energy*, 145, 1517–1527. <https://doi.org/10.1016/j.renene.2019.07.067>
- Rogado, A. (2018). *Sistema de Agregação de Dados Provenientes de Fontes de Energia Renováveis* [Dissertação]. Universidade Nova de Lisboa.
- Sideratos, G., & Hatziargyriou, N. D. (2007). An advanced statistical method for wind power forecasting. *IEEE Transactions on Power Systems*, 22(1), 258–265. <https://doi.org/10.1109/TPWRS.2006.889078>

- Singh, S., Bhatti, T. S., & Kothari, D. P. (2007). Wind Power Estimation Using Artificial Neural Network. *Journal of Energy Engineering*, 133(1), 46–52. [https://doi.org/10.1061/\(asce\)0733-9402\(2007\)133:1\(46\)](https://doi.org/10.1061/(asce)0733-9402(2007)133:1(46))
- Troen, I., & Petersen, E. L. (1989). *European Wind Atlas*. for the Commission of the European Communities.
- Xu, L., & Mao, J. (2016). *Short-Term Wind Power Forecasting Based on Elman Neural Network with Particle Swarm Optimization*. 1–4.
- Yang, B., Zhong, L., Wang, J., Shu, H., Zhang, X., Yu, T., & Sun, L. (2021). State-of-the-art one-stop handbook on wind forecasting technologies: An overview of classifications, methodologies, and analysis. In *Journal of Cleaner Production* (Vol. 283). Elsevier Ltd. <https://doi.org/10.1016/j.jclepro.2020.124628>
- Zhang, C., Wei, H., Xie, L., Shen, Y., & Zhang, K. (2016). Direct interval forecasting of wind speed using radial basis function neural networks in a multi-objective optimization framework. *Neurocomputing*, 205, 53–63. <https://doi.org/10.1016/j.neucom.2016.03.061>
- Zhang, J., Yan, J., Infield, D., Liu, Y., & Lien, F. sang. (2019). Short-term forecasting and uncertainty analysis of wind turbine power based on long short-term memory network and Gaussian mixture model. *Applied Energy*, 241, 229–244. <https://doi.org/10.1016/j.apenergy.2019.03.044>
- Zhao, P., Wang, J., Xia, J., Dai, Y., Sheng, Y., & Yue, J. (2012). Performance evaluation and accuracy enhancement of a day-ahead wind power forecasting system in China. *Renewable Energy*, 43, 234–241. <https://doi.org/10.1016/j.renene.2011.11.051>
- Zhao, Y., Ye, L., Li, Z., Song, X., Lang, Y., & Su, J. (2016). A novel bidirectional mechanism based on time series model for wind power forecasting. *Applied Energy*, 177, 793–803. <https://doi.org/10.1016/j.apenergy.2016.03.096>
- Zheng, H., & Wu, Y. (2019). A XGBoost model with weather similarity analysis and feature engineering for short-term wind power forecasting. *Applied Sciences (Switzerland)*, 9(15). <https://doi.org/10.3390/app9153019>



