



Previsão da Potência Média Produzida por Turbinas Eólicas Utilizando Redes Neurais

Letícia Góes Campos

Dissertação apresentada à Escola Superior de Tecnologia e de Gestão de Bragança para
obtenção do Grau de Mestre em Energias Renováveis e Eficiência Energética.

Trabalho orientado por:

Prof. João Paulo Teixeira

Prof. Raphael Paulo Braga Poubel

Bragança

Maio, 2025



Previsão da Potência Média Produzida por Turbinas Eólicas Utilizando Redes Neurais

Letícia Góes Campos

Dissertação apresentada à Escola Superior de Tecnologia e de Gestão de Bragança para
obtenção do Grau de Mestre em Energias Renováveis e Eficiência Energética.

Trabalho orientado por:

Prof. João Paulo Teixeira

Prof. Raphael Paulo Braga Poubel

Bragança

Maio, 2025

Agradecimentos

Agradeço aos meus pais, Ronaldo e Mary, por seu amor incondicional e por sempre investirem na minha educação. Sem vocês eu não estaria aqui hoje, e o esforço de vocês foi, sem dúvida, fundamental para o meu sucesso.

Agradeço ao amor da minha vida, meu marido Jânio, pelo companheirismo, pelo incentivo constante e por me fazer acreditar em mim até quando eu mesma duvido, desde a trajetória na engenharia até a mudança para outro país. Ter seu apoio com certeza transforma até as tarefas mais árduas em momentos leves e extraordinários.

Agradeço aos meus orientadores, João Paulo Teixeira, que desempenhou um papel fundamental na construção deste trabalho. Sua orientação, conhecimento e considerações foram essenciais para o desenvolvimento desta pesquisa. Agradeço também ao professor Raphael Poubel, por ter aceitado o desafio de me orientar à distância.

Agradeço aos meus amigos do CEFET, ao União, por todo suporte e rede de apoio. E principalmente a Áurea, Ana Marina e Lilian, por se fazerem presentes mesmo a distância.

Agradeço aos amigos que fiz em Bragança, Arthur, Hiago, Karol, Lê, San e Lari. Vocês contribuíram muito para eu me sentir acolhida e em casa.

Agradeço ao CEFET-MG por me proporcionar uma educação de extrema qualidade e por me proporcionar essa experiência de dupla diplomação. E agradeço ao IPB, instituição que me recebeu e me proporcionou além dos estudos, uma nova visão de mundo.

Abstract

This thesis presents the development and evaluation of artificial neural network models applied to short-term wind power generation forecasting in a wind farm. The main objective of the study was to explore the performance of Multi-Layer Perceptron (MLP) and Long Short-Term Memory (LSTM) architectures, using real data from wind turbines collected by SCADA systems between 2016 and 2017 in Portugal. Data preprocessing included normalization techniques, seasonal decomposition, and the construction of sliding windows for temporal modeling. Several configurations of MLP and LSTM were implemented, varying in the number of neurons, hidden layers, and training strategies, including early stopping and different data partitioning approaches. The evaluation employed statistical metrics to assess forecasting accuracy, including RMSE, NRMSE, and R^2 . Early stopping and randomized data splits were analyzed to enhance model performance and robustness. The models achieved results above 83% for the coefficient of determination (R^2). The main objective of this work was to develop MLP and LSTM models capable of accurately predicting the average power output of a wind turbine in a short-term horizon. To achieve this, different layer configurations, neuron counts, and validation techniques were tested for both approaches. Additionally, both single-variable and multivariable inputs were considered for the LSTM models. Finally, the three best-performing models were selected based on the evaluation metrics and compared with existing studies in the literature.

Keywords: Artificial Neural Networks, Wind Power, Multi-layer Perceptron, Python, Forecasting, Time Series Prediction, LSTM.

Resumo

Esta dissertação apresenta o desenvolvimento e a avaliação de modelos de redes neurais artificiais aplicados à previsão de curto prazo da geração de energia em um parque eólico. O objetivo principal do estudo foi explorar o desempenho das arquiteturas Multi-Layer Perceptron (MLP) e Long Short-Term Memory (LSTM) para a previsão da potência média produzida por uma turbina eólica em um horizonte de curto prazo, utilizando dados reais de turbinas eólicas coletados por sistemas SCADA no período de 2016 a 2017, em Portugal. O pré-processamento dos dados incluiu técnicas de normalização, decomposição sazonal e construção de janelas deslizantes para modelagem temporal. Diversas configurações de MLP e LSTM foram implementadas, com variações no número de neurónes, camadas ocultas e estratégias de treinamento, incluindo parada antecipada e diferentes formas de divisão dos dados. A avaliação utiliza métricas estatísticas para avaliar a precisão da previsão, incluindo RMSE, NRMSE e R^2 . Paradas antecipadas e divisões aleatórias do conjunto de dados foram avaliadas para aumentar o desempenho e a robustez do modelo. Os modelos obtiveram resultados acima de 85% para o coeficiente de determinação (R^2). Por fim, foram selecionados os três modelos com melhor desempenho de acordo com as métricas de avaliação e comparou-se com os trabalhos disponíveis na literatura.

Palavras-chave: Rede Neurais Artificiais, Energia Eólica, Perceptron Multicamadas, Predição de Séries Temporais, LSTM.

Conteúdo

1	Introdução	1
1.1	Contextualização	2
1.2	Objetivos	5
1.3	Estrutura	6
2	Estado da Arte	7
2.1	Fundamentos da Geração de Energia Eólica	7
2.2	A Necessidade de Previsão da Produção de Energia Eólica	9
2.3	Histórico dos Métodos de Previsão	12
2.4	Perceptron Multicamadas (MLP)	18
2.5	Redes Neurais Recorrentes (RNN) e LSTM	20
3	Materiais e Métodos	25
3.1	Base de Dados	26
3.1.1	Coleta de dados	26
3.1.2	Tratamento de dados	27
3.1.3	Decomposição Sazonal	28
3.1.4	Seleção de Variáveis para Entrada na Rede Neural	31
3.2	Arquitetura MLP	34
3.2.1	Pré - processamento	35
3.2.2	Hiperparâmetros	36
3.2.3	Modelos	37

3.3	LSTM com uma Variável	38
3.4	LSTM com Múltiplas Variáveis	41
3.5	Métricas de Avaliação	44
4	Resultados e Discussões	47
4.1	MLP	47
4.2	LSTM com uma variável de entrada	51
4.3	LSTM com múltiplas variáveis na entrada	54
4.4	Discussão	57
5	Conclusão	61
	Referências	62

Lista de Figuras

1.1	Geração de eletricidade e percentagem de participação, de acordo com o tipo de fonte, entre 2000 e 2050 (projeção PRIMES) [1].	3
2.1	Curva Típica de Potência da Turbina [24].	9
2.2	Modelo Esquemático de um Neurónio Artificial [21].	18
2.3	Representação de uma arquitetura MLP genérica [57].	19
2.4	Esquemático de uma Célula LSTM [59].	21
3.1	Série Temporal da energia média produzida entre 2016 e 2017.	27
3.2	Série Temporal da energia média produzida em Janeiro de 2016.	28
3.3	Decomposição da Série Temporal de Janeiro de 2016 a Dezembro de 2017 em Componentes de (a) Tendência, (b) Sazonalidade e (c) Residual.	29
3.4	Decomposição da produção média em janeiro de 2016 como (a) tendência, (b) sazonal e (c) componente residual.	30
3.5	Heat-map de correlação entre as variáveis do conjunto de dados.	33
3.6	Representação da divisão dos conjuntos de treino, validação e teste na série temporal.	36
3.7	Variação do Erro Quadrático Médio (MSE) de acordo com diferentes valores de <i>batch size</i>	41
4.1	Resultados de RMSE para Cada Modelo Proposto MLP.	49
4.2	Resultados de MAE para Cada Modelo Proposto MLP.	49
4.3	Resultados de R^2 para Cada Modelo Proposto MLP.	50

4.4	Sobreposição dos conjuntos de teste real e previsto para o modelo MLP P4.	51
4.5	Resultados de RMSE para Cada Modelo Proposto LSTM com uma Variável na Entrada.	52
4.6	Resultados de MAE para Cada Modelo Proposto LSTM com uma Variável na Entrada.	53
4.7	Resultados de R^2 para Cada Modelo Proposto LSTM com uma Variável na Entrada.	53
4.8	Sobreposição dos conjuntos de teste real e previsto para o modelo U3 (LSTM com entrada única).	54
4.9	Resultados de RMSE para Cada Modelo Proposto LSTM com Múltiplas Variáveis na Entrada.	55
4.10	Resultados de MAE para Cada Modelo Proposto LSTM com Múltiplas Variáveis na Entrada.	56
4.11	Resultados de R^2 para Cada Modelo Proposto LSTM com Múltiplas Variáveis na Entrada.	57

Lista de Tabelas

2.1	Categorização da Previsão de Energia Eólica de acordo com o Horizonte de Previsão.	11
2.2	Resumo dos Métodos Geralmente Aplicados para Previsão de Geração de Energia Eólica	17
3.1	Variáveis com maior correlação positiva com a potência média gerada. . . .	34
3.2	Hiperparâmetros para os Modelos MLP Desenvolvidos.	37
3.3	Resumo Descritivo dos Modelos MLP.	38
3.4	Resumo Descritivo dos Modelos LSTM com uma Variável.	39
3.5	Resumo Descritivo dos Modelos LSTM múltiplas variáveis.	44
4.1	Resultados das Métricas de Erro para os Modelos MLP Desenvolvidos. . . .	48
4.2	Resultados para o Modelo LSTM Univariado	51
4.3	Resultados para o Modelo LSTM com Múltiplas Variáveis	54
4.4	Comparação entre os Resultados dos Modelos Apresentados	58
4.5	Comparação dos Resultados dos Modelos Propostos com Trabalhos da Literatura	58

Acrônimos

ARIMA Média Móvel Integrada Autorregressiva.

ESTiG Escola Superior de Tecnologia e Gestão.

IPB Instituto Politécnico de Bragança.

LSTM Long Short-Term Memory.

MAE Erro Médio Absoluto.

MAPE Erro Percentual Absoluto Médio.

MLP Perceptron Multicamadas.

MSE Erro Quadrático Médio.

NRMSE Raiz do Erro Quadrático Médio Normalizado.

RMSE Raiz do Erro Quadrático Médio.

RNA Rede Neural Artificial.

SARIMA Seasonal Autoregressive Integrated Moving Average.

SCADA Controle de Supervisão e Aquisição de Dados.

Capítulo 1

Introdução

Nos últimos anos, o setor de energia tem assistido a um crescimento expressivo da capacidade instalada de geração eólica, impulsionado por avanços tecnológicos e pela necessidade de transição para fontes mais sustentáveis. Esse movimento é particularmente notável na União Europeia, onde políticas ambientais e metas de descarbonização têm promovido um aumento acelerado na participação da energia eólica na matriz elétrica, com projeções que indicam um crescimento de 400% entre 2015 e 2050 [1].

Apesar dos benefícios ambientais e econômicos associados à energia eólica, sua crescente penetração no sistema elétrico impõe desafios significativos à operação da rede, sobretudo devido à variabilidade e à incerteza inerentes à fonte. A intermitência da geração eólica pode comprometer a estabilidade da rede, tornando essencial o desenvolvimento de estratégias para mitigar seus impactos.

Nesse contexto, a previsão da geração eólica, especialmente em horizontes de curto e ultra-curto prazo, surge como uma ferramenta crítica para facilitar a integração segura e eficiente dessa fonte renovável. Técnicas modernas de previsão, muitas vezes baseadas em inteligência artificial e aprendizado de máquina, têm demonstrado elevado potencial na melhoria da acurácia preditiva, contribuindo para decisões operacionais mais seguras e eficazes.

Este capítulo introduz o contexto em que está inserido este trabalho de mestrado. O panorama atual da energia eólica, destacando seu crescimento e importância na Europa,

os desafios de integração ao sistema elétrico e o papel estratégico das técnicas de previsão como solução para garantir a confiabilidade e sustentabilidade da rede elétrica moderna. Também são apresentados os objetivos da pesquisa e a estrutura desse documento.

1.1 Contextualização

Desde o início dos anos 2000 na União Europeia, a geração de energia por turbinas eólicas têm alcançado taxas de crescimento constante, como pode ser visto na Figura 1.1. Em 2020, cerca de 16% da demanda de eletricidade na União Europeia foi atendida por usinas eólicas onshore e offshore [1].

Considerando o cenário global, a energia eólica é a segunda maior energia renovável em implantação, atrás apenas da energia hidroelétrica. Em termos de aumento de capacidade está atrás apenas da energia solar, atingindo o valor de 51 GW adicional em 2018 [2].

No contexto da matriz energética da União Europeia, a energia eólica ocupa posição de destaque como o segmento de crescimento mais acelerado. Projeta-se um aumento de 400% na capacidade instalada entre os anos de 2015 e 2050. A energia eólica deverá representar 30% da geração líquida total de eletricidade até 2030, partindo de 127 GW em 2015 para 349 GW em 2030 e com projeção para atingir 508 GW em 2050 [1].

A energia eólica vem se consolidando como uma das fontes renováveis mais promissoras, tanto por sua eficiência crescente quanto por sua competitividade económica. Turbinas eólicas terrestres vêm operando com índices de eficiência superiores a 80% em locais favoráveis, evidenciando o aproveitamento eficaz do potencial eólico [3]. A adoção de tecnologias modernas, como conversores baseados em carboneto de silício, tem contribuído para melhorar a eficiência e reduzir custos dos sistemas de conversão de energia eólica [4].

Do ponto de vista económico, estudos recentes indicam que a energia eólica vem se tornando cada vez mais competitiva em comparação com outras fontes renováveis, como a solar e a hidroelétrica. Em regiões com elevados índices de velocidade do vento, o custo nivelado da eletricidade eólica tem diminuído significativamente, tornando-a uma alternativa viável em comparação com as fontes convencionais de geração [5].

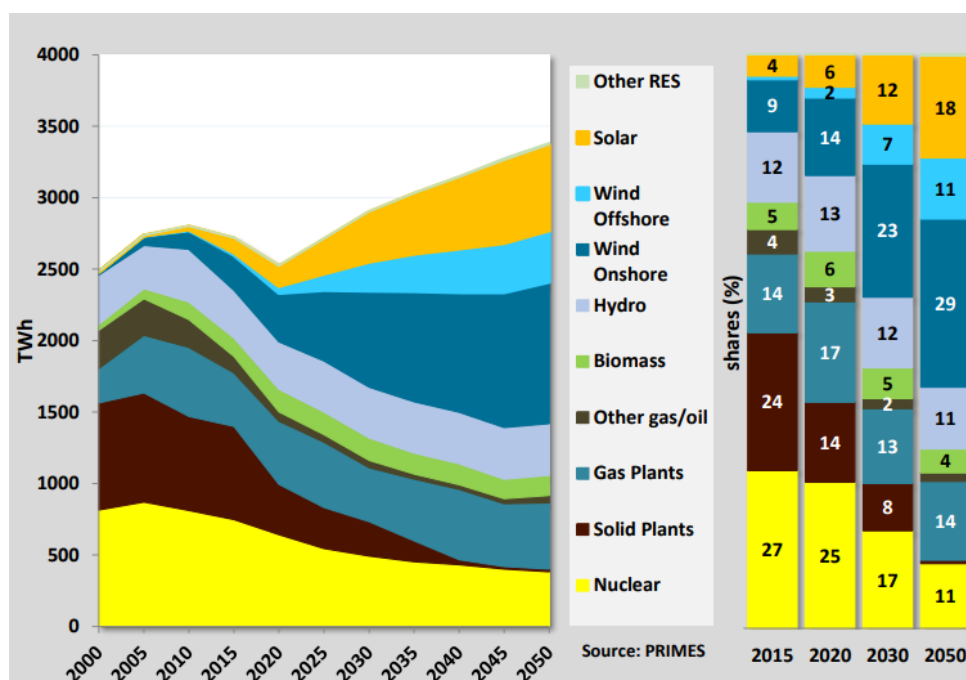


Figura 1.1: Geração de eletricidade e percentagem de participação, de acordo com o tipo de fonte, entre 2000 e 2050 (projeção PRIMES) [1].

A pesquisa no tema de previsão de energia eólica evoluiu consideravelmente, passando dos métodos tradicionais de previsão pontual para abordagens probabilísticas mais sofisticadas.

Modelos estatísticos que utilizam apenas dados históricos de velocidade e potência do vento foram desenvolvidos com modelos únicos ou híbridos de vários métodos, como média móvel integrada autorregressiva (ARIMA), filtros de Kalman, redes neurais artificiais e teoria bayesiana. Porém, devido ao caráter intrínseco não estacionário do vento, esses modelos são mais eficazes para previsões de curto prazo (até quatro horas à frente) e apresentam erros maiores conforme o horizonte de previsão aumenta [6].

Alguns dos estudos analisados destacam a importância da colaboração interdisciplinar e da utilização de modelos híbridos que combinam abordagens físicas e estatísticas. Essa tendência aponta para estruturas de previsão mais robustas e abrangentes [7]. Paralelamente, algoritmos de aprendizado profundo, como Long Short-Term Memory (LSTM) e AutoEncoders, têm se destacado por sua capacidade de superar modelos tradicionais em

tarefas de previsão de energia renovável [8]. Isso reflete o reconhecimento crescente das complexidades envolvidas na modelagem precisa da geração de energia eólica.

A integração de processos Extreme Learning Machines (ELM) e Processos Gaussianos (GP) podem contribuir para o aumento de precisão da previsão. O primeiro escolhe aleatoriamente os pesos de entrada dos neurônios da camada oculta e determina os pesos de saída por meio de cálculos matriciais simples, destacando-se por uma alta velocidade de treinamento. Os Processos Gaussianos são úteis ao incorporar incertezas e capturar padrões complexos e não estacionários nas séries temporais de vento e potência [9], [10].

Em uma rede de transmissão de energia cada vez mais interligada, a falha de um único componente pode sobrecarregar linhas adjacentes ou acionar proteções, desencadeando desligamentos em cadeia [11]. Falhas em cascata são uma das principais causas de apagões em sistemas elétricos ao redor do mundo, como relatado em diferentes casos entre 2000 e 2010 na América do Norte, Europa e Brasil [12].

Em abril de 2025, a Península Ibérica enfrentou um apagão de grandes proporções, cuja causa ainda está sendo investigada. A interrupção afetou o sistema de telecomunicações, provocou o cancelamento de voos e comprometeu serviços ferroviários. Como o evento é recente, as informações disponíveis provêm exclusivamente da comunicação social.

O apagão teve início com a perda de geração na subestação de Granada, por motivos ainda não esclarecidos, seguida, poucos segundos depois, por falhas em Badajoz e Sevilha [13]. Em pouco tempo, a falta de distribuição de eletricidade se estendeu a outras partes da Espanha e a Portugal.

Dada a magnitude do evento, a reativação da rede exige um processo cuidadoso conhecido como *black start*, uma retomada gradual da geração e distribuição de energia [14].

As evidências atuais sugerem que o problema pode ter sido causado por uma falha na sincronização da rede elétrica. Para que o sistema funcione corretamente, todas as fontes de geração devem operar em uma frequência padrão, definida na Europa em 50 hertz. Essa sincronização depende de uma base energética estável, geralmente fornecida por usinas nucleares, hidrelétricas e grandes termelétricas a gás. Essas fontes atuam como estabilizadores naturais, ajudando a manter a frequência constante diante de variações

súbitas na demanda ou na geração [15].

Fontes renováveis intermitentes, como as fontes fotovoltaica e eólica, não oferecem a mesma estabilidade. Embora gerem corrente contínua que é convertida em corrente alternada a 50 hertz, elas não reagem automaticamente a flutuações de frequência [15].

Embora a rede elétrica geralmente consiga lidar com pequenas perturbações, como oscilações de frequência ou a parada inesperada de uma usina, parte dessa resiliência depende de tecnologias tradicionais de geração, que estão sendo progressivamente substituídas por fontes renováveis menos previsíveis [16].

Considerada essa vulnerabilidade, previsões precisas de geração, como a previsão probabilística da energia eólica (PWPP), são utilizadas para mitigar riscos operacionais e garantir a estabilidade da rede [17], [18].

Técnicas modernas como redes neurais convolucionais (CNN) têm aprimorado a acurácia das previsões em horizontes de curto e ultra-curto prazo, com horizonte de minutos até algumas horas, permitindo uma melhor programação e controle da geração de energia eólica [19]. A combinação de diferentes modelos, como redes neurais e análises estatísticas, permite uma melhor avaliação de riscos pelos operadores e decisões mais informadas sobre despacho de energia e gestão de reservas [20], [21]. Ao fornecer previsões confiáveis, esses métodos contribuem diretamente para uma integração mais eficiente da energia eólica à matriz elétrica, promovendo um sistema mais estável e economicamente sustentável [18].

1.2 Objetivos

Este trabalho propõe o desenvolvimento e a avaliação de modelos baseados em redes neurais artificiais para a previsão de curto prazo da geração de energia em um parque eólico. Utilizando dados reais obtidos por sistemas SCADA em turbinas instaladas em Portugal, são implementadas e comparadas diferentes configurações de redes MLP e LSTM, com foco na acurácia da previsão. O estudo busca identificar as melhores estratégias de modelagem para contribuir com a operação eficiente de sistemas de geração eólica conectados

à rede.

Para atingir esse objetivo geral, foram definidos os seguintes objetivos específicos:

- Analisar uma base de dados com valores reais de turbinas eólicas instaladas em Portugal considerando diferentes abordagens de pré-processamento;
- Desenvolver diferentes modelos de redes neuronais artificiais, nomeadamente usando as arquiteturas MLP e LSTM, registrando os valores de erros e acurácia;
- Comparar os resultados obtidos com trabalhos relacionados e entre os modelos para definir a melhor solução.

1.3 Estrutura

Esta dissertação é composta por cinco capítulos, organizados da forma descrita a seguir. O primeiro capítulo apresenta uma visão geral do estudo, incluindo a contextualização do tema, a relevância do assunto abordado e os objetivos gerais e específicos da pesquisa. O Capítulo 2 apresenta a fundamentação teórica e o panorama atual das técnicas de previsão de geração eólica. No Capítulo 3 são detalhados os materiais e métodos utilizados, incluindo a descrição da base de dados e a implementação dos modelos. O Capítulo 4 apresenta os resultados obtidos e uma discussão comparativa dos resultados obtidos com os resultados do estado da arte. Por fim, o Capítulo 5 traz as conclusões do trabalho e sugestões para pesquisas futuras.

Capítulo 2

Estado da Arte

Este capítulo apresenta uma revisão abrangente dos fundamentos, aplicações e avanços metodológicos relacionados à previsão da geração de energia eólica. Inicialmente, são abordados os princípios físicos que regem o funcionamento das turbinas eólicas, com ênfase na conversão da energia cinética do vento em eletricidade. Em seguida, discute-se a importância estratégica da previsão da geração eólica, destacando seu papel na estabilidade da rede elétrica, no planejamento operacional e na viabilidade econômica da inserção de fontes renováveis.

O capítulo também examina a evolução dos métodos de previsão, desde abordagens físicas e estatísticas até modelos baseados em inteligência artificial e estruturas híbridas, evidenciando suas vantagens, limitações e aplicações práticas. Por fim, são apresentados exemplos relevantes da literatura que ilustram o desempenho e a eficácia desses modelos em diferentes contextos, consolidando o panorama atual da área e fundamentando as escolhas metodológicas adotadas nesta pesquisa.

2.1 Fundamentos da Geração de Energia Eólica

A geração de energia eólica ocorre por meio da conversão da energia cinética do vento em energia elétrica.

O princípio de funcionamento da conversão envolve as turbinas eólicas (aerogeradores),

em que as massas de ar entram em contato com as pás das turbinas, provocando sua rotação. Essa energia rotacional é transferida para um gerador elétrico, que converte o movimento mecânico em eletricidade por indução eletromagnética [22].

As especificações técnicas do aerogerador irão determinar a faixa de potência do equipamento, que pode variar desde centenas até megawatts [21]. As principais características incluem o diâmetro do rotor, que define a área de varredura, a altura do eixo, o qual influencia na captação de ventos mais constantes, a curva de potência da turbina e os limites operacionais de velocidade do vento.

A máxima potência que pode ser extraída por uma turbina eólica é deduzida a partir das equações de energia cinética, da potência disponível dos ventos e da fração da potência eólica disponível que é capturada pelas pás do rotor [23]. Sendo assim, a máxima potência de uma turbina eólica é definida pela Equação 2.1 a seguir.

$$P(v) = \frac{\rho A v^3 C_p}{2} \quad (2.1)$$

Na qual:

- $P(v)$ denota a potência de saída da turbina eólica em watts.
- ρ refere-se a a densidade do ar em kg/m^3 .
- A representa a área da seção transversal, ou área de varredura, em m^2 .
- v representa a velocidade do vento em m/s .
- C_p é o coeficiente de potência da turbina.

A curva de potência de uma turbina eólica em função da velocidade do vento apresenta um formato típico, como ilustrado na Figura 2.1. Em que abaixo da velocidade de corte inicial (*cut-in*) a turbina eólica não produz eletricidade. Entre as velocidades de corte inicial (*cut-in*) e nominal (*rated*), a produção de potência segue as leis físicas conforme definido na Equação 2.1. Entre as velocidades nominal (*rated*) e de corte final (*cut-out*),




Figura 2.1: Curva Típica de Potência da Turbina [24].

a turbina opera em sua capacidade máxima de geração elétrica. Acima da velocidade de corte final (*cut-out*), a turbina é desligada para evitar danos na estrutura [22].

Na Figura 2.1, a sigla VC representa a velocidade de corte inicial ou *cut-in*, VR é a velocidade nominal ou *rated* e VF significa a velocidade de corte final ou *cut-out*.

Tipicamente, os valores para esses limites são: velocidade de corte inicial entre 4 a 5 m/s, velocidade nominal entre 11 e 17 m/s e velocidade de corte final entre 25 a 30 m/s [21], [24].

2.2 A Necessidade de Previsão da Produção de Energia Eólica

A previsão da energia eólica oferece vários benefícios significativos que aumentam a eficiência e a confiabilidade dos sistemas de energia. Previsões precisas permitem um melhor planejamento e ajuste do fornecimento de energia ao longo da rede, o que é crucial para integrar recursos renováveis como a energia eólica no mercado de eletricidade. A maior

previsibilidade pode levar a estratégias de licitação otimizadas nos mercados de eletricidade, garantindo que os fornecedores de energia possam atender à demanda e, ao mesmo tempo, minimizar os custos [25].

Uma vez que a geração eólica tem a natureza de ser inerentemente imprevisível e com o crescimento esperado na capacidade instalada de geração, faz-se necessária uma preparação para a conexão à rede de transmissão elétrica. A incerteza aumentada proveniente da geração eólica pode levar a falhas em cascata na rede. Quanto maior o nível de incerteza introduzido, mais crítica se torna a situação em relação ao número total de linhas desconectadas e casos de corte de carga [26], [27].

Em casos mais extremos, essa situação pode levar a apagões [11], como ocorreu em casos marcantes na América do Norte em agosto de 2003, na Alemanha em novembro de 2006 e no Brasil em novembro de 2009 [12].

Um dos exemplos mais recentes de falha no fornecimento de energia elétrica ocorreu na Península Ibérica, em abril de 2025. Embora as causas iniciais ainda estejam sob investigação, o evento desencadeou uma falha em cascata que afetou amplamente Espanha e Portugal [16].

Em Portugal, estima-se que o apagão ocorrido em 28 de abril tenha causado prejuízos na ordem dos 2 mil milhões de euros às empresas, conforme apontado por um estudo da Associação Industrial Portuguesa (AIP). A associação reforça que os prejuízos financeiros foram praticamente generalizados entre as empresas afetadas, com destaque para o setor industrial, que registou as perdas mais expressivas [28].

A previsão de energia tem uma contribuição significativa para ajudar a manter a estabilidade dos sistemas elétricos e otimizar a produção de energia. Previsões precisas desempenham um papel fundamental na gestão da variabilidade inerente da energia eólica, sendo essencial para a integração adequada de fontes renováveis à rede elétrica [17].

Devido à natureza estocástica e à forte flutuação da geração de energia eólica, uma função importante da previsão de energia é mitigar a variabilidade. Além disso, os benefícios incluem fatores económicos como a redução de custos e a competitividade no mercado. Previsões precisas podem reduzir os custos operacionais e aprimorar as estratégias de

gestão de carga ao mitigar a exposição ao risco [29].

A previsão da geração de energia para fontes renováveis geralmente é classificada de acordo com o horizonte temporal da previsão. Nesta classificação tem-se o horizonte ultra-curto prazo, em que a unidade de previsão é em minutos; o curto prazo, em que a previsão considera de uma a várias horas no futuro; médio prazo, variando de diário a semanal; e o horizonte de longo prazo, com previsão em anos [30]. A classificação é apresentada de forma resumida na tabela 2.1

Tabela 2.1: Categorização da Previsão de Energia Eólica de acordo com o Horizonte de Previsão.

Categoria	Período previsto
Ultra-curto prazo	Minutos
Curto prazo	De uma a várias horas
Médio prazo	Dias a semanas
Longo prazo	Meses a anos

Os impactos positivos da previsão variam de acordo com o intervalo de tempo da saída da previsão. Previsões de ultra-curto prazo são essenciais para a gestão da rede; previsões de curto prazo são necessárias para o controle de sistemas de potência, programação de unidades, análise de segurança do sistema e confiabilidade do sistema. Além disso, a previsão de curto prazo é crucial para a integração de fontes de energia renovável ao sistema elétrico, ajudando a manter a estabilidade da rede e permitindo que os operadores girem as flutuações de forma produtiva [31]. Previsões de médio prazo contribuem para o planejamento da manutenção da rede, e previsões de longo prazo são cruciais para a organização da expansão da rede [32].

As previsões de energia eólica desempenham um papel crucial na manutenção da estabilidade da rede devido à variabilidade inerente da geração de energia eólica. A previsão precisa ajuda os operadores de sistemas de transmissão (TSOs) a equilibrar a oferta e a demanda ao prever a alimentação das turbinas eólicas, o que é essencial para o gerenciamento e a confiabilidade da rede [33].

Com a rápida expansão da capacidade instalada de geração eólica, surgem desafios para os sistemas elétricos de potência. Uma previsão eficaz é vital para mitigar os impactos

económicos da geração intermitente e garantir um fornecimento estável de eletricidade [34], [35].

No geral, a previsão eficaz de energia eólica não apenas apoia a estabilidade da rede, mas também promove a viabilidade económica de fontes de energia renováveis [18].

Com o aprimoramento dos métodos de previsão, eles não apenas aumentam a eficiência operacional, mas também impulsionam a necessidade de regulamentações atualizadas que reflitam a natureza dinâmica da produção de energia eólica e sua integração no mercado de energia mais amplo [36], [37].

2.3 Histórico dos Métodos de Previsão

Os métodos existentes para previsão de geração de energia eólica podem ser classificados em quatro categorias: físicos, estatísticos, métodos com uso de inteligência computacional ou *machine learning* e métodos híbridos [38], [39].

O sistema de previsão numérica do tempo (NWP – *Numerical Weather Prediction*) fornece estimativas da velocidade do vento em uma grade de pontos ao redor dos geradores eólicos, com resolução espacial variável conforme o tipo de sistema utilizado. Este modelo físico descreve a relação entre a velocidade do vento, as condições atmosféricas, a topografia local e o desempenho do parque eólico. Ele é composto por diversos submodelos que, em conjunto, transformam as previsões de vento da grade em estimativas aplicáveis aos pontos específicos de interesse [21].

Desenvolvido a partir de dados reais de parques eólicos na República Tcheca, foi proposto um método simples e eficaz para prever a geração de energia eólica com base em dados de modelos numéricos avançados de previsão do tempo (NWP). Capaz de estimar a produção para prazos de até 72 horas, o estudo avalia três modelos de previsão diferentes e combina funções de potência sigmoideal com previsões de velocidade do vento a partir de um modelo NWP de mesoescala. O modelo foi implementado em um sistema chamado “FOREG”, usado pela empresa Tcheca de distribuição de energia (CEZ) e é executado quatro vezes ao dia pela empresa, garantindo a atualização contínua das previsões [40].

O principal desafio na aplicação prática do modelo físico é a necessidade que se impõe da coleta de uma descrição detalhada do terreno ao redor dos geradores. Além disso, modelos físicos de alta precisão exigem grande poder computacional, o que pode inviabilizar seu uso em previsões de curto prazo [38].

Modelos estatísticos apresentam menor custo computacional quando comparados aos modelos físicos de alta precisão. Sua principal limitação é o aumento do erro à medida que o horizonte de previsão aumenta, tornando-os mais adequados para previsões de curto prazo [38], [39].

Entre os métodos estatísticos mais utilizados estão os modelos autorregressivos (AR), autorregressivos de média móvel (ARMA) e autorregressivos integrados de média móvel (ARIMA). O modelo ARIMA é composto por três componentes: a parte autorregressiva (AR), que representa a relação entre observações atuais e passadas, indicada pela ordem 'p'; a parte integrada (I), que torna a série estacionária por meio da diferenciação, indicada pela ordem 'd'; e a parte de média móvel (MA), que modela a dependência entre a observação atual e os erros residuais passados, representada pela ordem 'q' [41]–[43].

A aplicação do modelo ARIMA inicia-se com a transformação da série de velocidade do vento em uma série estacionária, utilizando a diferenciação. Em seguida, os parâmetros (p, d, q) são determinados com base em funções de autocorrelação [42]. Após o ajuste, o modelo é capaz de prever velocidades futuras do vento, que são convertidas em estimativas de geração de energia por meio da curva de potência da turbina [6].

O modelo ARIMA também serve como base de comparação para outros métodos, como modelos de aprendizagem máquina, devido à sua estrutura clara e desempenho consolidado na previsão de curto prazo [6], [44].

É importante destacar que os métodos estatísticos dependem fortemente das previsões numéricas do tempo, que, por sua vez, são limitadas pela qualidade e disponibilidade dos dispositivos de monitoramento instalados nas centrais eólicas [38].

Tanto os modelos estatísticos quanto os que utilizam redes neurais artificiais geralmente se baseiam em dados históricos das turbinas e das condições locais do parque eólico. Esses métodos buscam identificar e modelar relações não lineares entre as variáveis

de entrada e saída, oferecendo como vantagem o baixo custo operacional [45].

Um exemplo de aplicação é o protótipo do algoritmo California ISO para previsão de energia eólica em curto prazo, que utilizou o modelo ARIMA para calcular fatores de aumento ou redução da geração com até 2,5 horas de antecedência [46]. Os coeficientes do modelo eram ajustados dinamicamente para melhorar a precisão, e um esquema de autocorreção foi incorporado por meio da adição de um termo extra ao modelo ARIMA modificado. Porém, nesse estudo destacou-se a importância de integrar parâmetros meteorológicos previstos e informações sobre o status operacional das unidades geradoras ao modelo.

Conforme as limitações dos métodos tradicionais de previsão se tornaram mais evidentes, surgiram técnicas de inteligência computacional, com destaque para as redes neurais artificiais (RNAs), que demonstraram desempenho superior na identificação de padrões complexos nas flutuações da velocidade do vento [44].

A incorporação de RNAs na previsão da velocidade e potência do vento resultou em ganhos significativos de precisão, reduzindo os erros de previsão e aumentando a confiabilidade da previsão de geração eólica [44].

Um exemplo prático dessa aplicação foi a previsão da produção de energia eólica com um dia de antecedência na Alemanha, utilizando parâmetros meteorológicos históricos previstos e dados de potência medidos simultaneamente [33]. Durante a fase de treinamento da RNA, buscou-se compreender a relação física entre a velocidade do vento e a produção de energia. Um dos diferenciais desse método é a incorporação de variáveis meteorológicas adicionais, como pressão atmosférica e temperatura, além do uso das curvas de potência específicas de cada planta, o que contribuiu para o aumento da precisão das previsões.

De entre as arquiteturas mais utilizadas, destaca-se o Perceptron Multicamadas (MLP), uma rede do tipo *feedforward* aplicada amplamente em tarefas de otimização, reconhecimento de padrões e previsão. O MLP tem sido empregado como modelo de regressão empírica, especialmente em casos de regressão não linear [47].

O MLP tem apresentado maior acurácia em relação a modelos tradicionais, como

o ARIMA, e sua estrutura mais simples possibilita tempos de previsão mais curtos, tornando-a adequada para aplicações em tempo real. Além disso, o MLP é considerado um aproximador universal, sendo capaz de representar qualquer função contínua com uma única camada oculta, desde que contenha número suficiente de neurónios [48].

Apesar das vantagens, o uso de RNAs enfrenta desafios. Um deles é a necessidade de grandes volumes de dados de entrada para o treinamento, o que pode levar ao sobreajuste, situação em que o modelo apresenta bom desempenho nos dados de treinamento, mas falha ao generalizar para novos dados. As RNAs também podem apresentar dificuldades com erros de extrapolação, especialmente ao realizar previsões fora do intervalo observado nos dados de treinamento, comprometendo a confiabilidade em cenários com condições de vento altamente variáveis. Outro entrave é o alto custo computacional envolvido no treinamento e na execução desses modelos, principalmente em arquiteturas mais complexas, o que limita sua aplicação prática em sistemas que exigem respostas em tempo real [49].

Nos últimos anos, as RNAs evoluíram significativamente na previsão de energia eólica, capturando com mais eficácia a dinâmica espacial e temporal complexa dos dados eólicos. Diversas arquiteturas avançadas têm sido estudadas, incluindo CNN-RNN, LSTM e redes neurais gráficas.

A arquitetura CNN-RNN combina redes neurais convolucionais (CNNs), responsáveis pela extração de características espaciais, com redes neurais recorrentes (RNNs), que analisam a sequência temporal dos dados. Essa abordagem tem superado os métodos tradicionais na previsão de energia com um dia de antecedência, especialmente quando treinada com dados provenientes de diferentes modelos climáticos e parques eólicos [50].

As redes de memória de longo prazo (LSTM) destacam-se na modelagem de dependências temporais de longo alcance, capturando relações não lineares entre a velocidade do vento e a produção de energia, o que resulta em maior precisão na previsão de curto prazo [51].

O uso de modelos híbridos, que combinam diversos algoritmos, tem se mostrado eficaz na redução de erros de previsão, aumentando a eficiência operacional e a confiabilidade dos sistemas de geração eólica [52].

Em uma revisão de literatura com mais de 100 artigos analisados, Qian et al. classificam os modelos híbridos em três estruturas principais [53]:

- Estrutura 1: A série temporal da velocidade do vento é decomposta em subséries com características relativamente estacionárias. Cada subsérie é então analisada e prevista utilizando diferentes modelos, e as previsões individuais são combinadas para gerar o resultado final.
- Estrutura 2: Semelhante à Estrutura 1, mas com uma etapa adicional de decomposição. As subséries iniciais são novamente decompostas em componentes ainda mais estacionários utilizando um segundo método de decomposição. Apesar de aumentar a precisão, essa abordagem exige maior custo computacional.
- Estrutura 3: Apenas um modelo de previsão é construído, e as entradas são selecionadas diretamente a partir das subséries decompostas. Essa estrutura é computacionalmente mais eficiente e demonstrou desempenho superior à Estrutura 1 em horizontes de curto prazo.

Na Índia, técnicas de redes neurais artificiais (RNAs), como redes *feed-forward* e recorrentes, foram integradas a métodos estatísticos de séries temporais para prever velocidades do vento diárias e mensais em estudo [43]. Os resultados indicaram que as RNAs superam os modelos ARIMA em precisão. No entanto, é importante observar que médias diárias e mensais de velocidade do vento tendem a ser mais suaves do que dados horários, o que facilita previsões mais precisas nesses intervalos.

Na Escócia, tem-se um exemplo recente com a combinação entre o modelo LSTM, um tipo de rede neural recorrente, com o modelo SARIMA, aplicada à previsão da geração de uma turbina offshore. Os resultados obtidos indicaram elevada eficiência do modelo híbrido, com acurácia superior a 99% em diferentes níveis de decomposição e detalhamento [54].

Adicionalmente, estratégias de decomposição vêm sendo amplamente combinadas com modelos híbridos. Tais abordagens dividem a série temporal da velocidade do vento ou da

potência gerada em sub-séries mais estacionárias, facilitando a modelagem subsequente. Entre os métodos mais utilizados destaca-se a transformada wavelet (WT), que separa o sinal em componentes de alta e baixa frequência, tornando-os mais estáveis e analisáveis [55].

Um resumo dos principais métodos utilizados e estudados atualmente para a previsão de energia eólica é apresentado na Tabela 2.2.

Tabela 2.2: Resumo dos Métodos Geralmente Aplicados para Previsão de Geração de Energia Eólica

Abordagem	Modelos	Casos de Utilização
Física	Sistema de previsão numérica do tempo (NWP).	Na República Tcheca, um modelo proposto utilizando NWP foi adotado pela empresa de distribuição de energia, sendo executado continuamente e capaz de prever com até 72h de antecedência [40].
Estatística	Modelos autorregressivos (AR), autorregressivos de média móvel (ARMA) e autorregressivos integrados de média móvel (ARIMA).	Protótipo do algoritmo California ISO para previsão de energia eólica em curto prazo, que utilizou o modelo ARIMA para calcular fatores de aumento ou redução da geração com até 2,5 horas de antecedência [46].
Redes Neurais	Os modelos variam em diferentes arquiteturas como MLP, LSTM e CNN.	Um exemplo prático dessa aplicação foi a previsão da produção de energia eólica com um dia de antecedência na Alemanha, utilizando parâmetros meteorológicos históricos previstos e dados de potência medidos simultaneamente [33].
Híbrida	Modelos combinando diferentes abordagens, como Redes Neurais e métodos estatísticos.	Na Índia [43] e Escócia [54], respectivamente, RNAs integradas a métodos estatísticos de séries temporais e a combinação de modelos LSTM e SARIMA foram descritas em estudos.




Figura 2.2: Modelo Esquemático de um Neurônio Artificial [21].

2.4 Perceptron Multicamadas (MLP)

A arquitetura Perceptron Multicamadas (MLP) é um tipo de rede neuronal que oferece várias vantagens para a previsão de séries temporais. Uma rede neuronal MLP compreende unidades de processamento, chamadas neurónios, organizadas em camadas: a camada de entrada, uma ou mais camadas ocultas e a saída. Cada camada contém um número específico de neurónios. Esses neurónios são interconectados por meio de pesos. Cada camada recebe sinais de entrada da camada anterior, os processa usando uma função de ativação e transmite os sinais de saída resultantes para a próxima camada por meio dos neurónios [47].

Na Figura 2.2 é mostrado um modelo esquemático de um neurônio artificial.

De acordo com a forma em que as camadas estão interligadas, as redes neuronais podem ser classificadas como redes de *feedforward* (também chamadas de acíclicas) ou *feedback* (também conhecidas como cíclicas ou recorrentes). No primeiro tipo, os dados circulam numa única direção, partindo da camada de entrada para as camadas intermédias, se existirem, e depois para a camada de saída. As redes do segundo tipo possuem conexões de feedback, ou seja, a saída de algum neurónio em uma camada é usada como entrada para neurónios em camadas com índice menor ou igual. Dessa forma, os níveis de ativação da rede formam um sistema dinâmico [56].

O MLP é caracterizado por um fluxo de informação unidirecional e ausência de laços

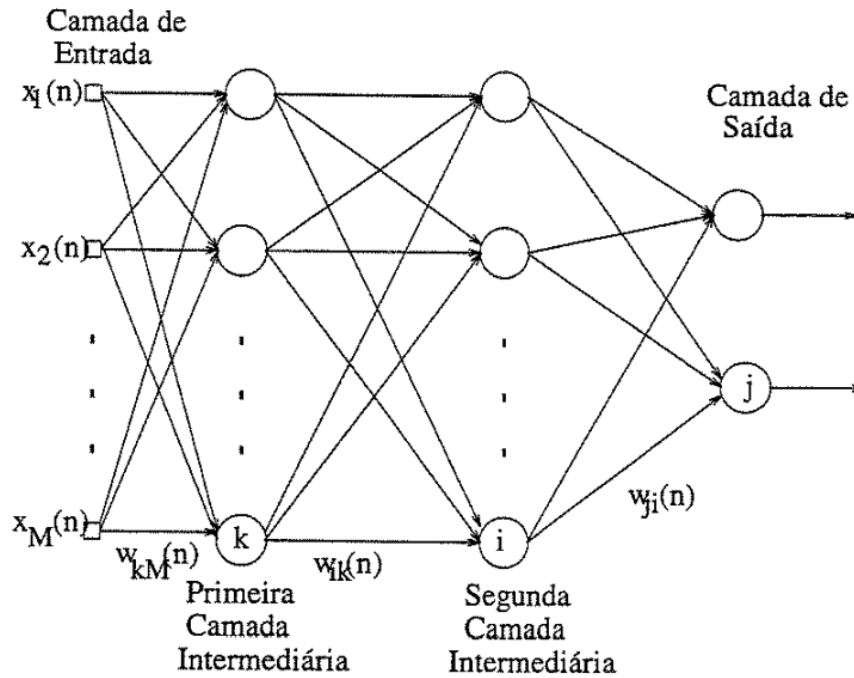


Figura 2.3: Representação de uma arquitetura MLP genérica [57].

de *feedback* em sua arquitetura padrão, portanto, é classificado como uma rede *feedforward* ou acíclica. O treinamento de um MLP é frequentemente realizado utilizando o algoritmo de *backpropagation*, em que são modificados os pesos da rede neuronal de forma ordenada para alcançar uma saída desejada. Em outras palavras, o objetivo do algoritmo é minimizar o erro entre a saída produzida pela rede e a saída desejada (*target*).

Na Figura 2.3 é ilustrada a arquitetura de uma rede neuronal genérica MLP com duas camadas escondidas/intermédias.

O algoritmo de retropropagação, pode ser classificada entre não supervisionada e supervisionada. No primeiro caso, o algoritmo processa um conjunto de entradas e organiza os dados em estruturas de acordo com princípios de auto-organização. No segundo caso, o processo de treinamento é realizado ajustando os pesos de camadas sucessivas em uma sequência de iterações ou épocas. Para esse propósito, ele é definido como um vetor de entrada e um vetor de saída correspondente, gerando múltiplos casos de treinamento [56], [58].

2.5 Redes Neurais Recorrentes (RNN) e LSTM

As Redes Neurais Recorrentes (RNNs) são arquiteturas projetadas para o processamento de dados sequenciais, caracterizando-se pela manutenção de um estado oculto que armazena informações de entradas anteriores. Essa capacidade permite que aprendam padrões ao longo do tempo, sendo especialmente úteis em tarefas como previsão de séries temporais e análise de comportamento, nas quais a identificação de dependências temporais é fundamental. Por meio de ciclos de realimentação, as RNNs atualizam suas saídas com base em dados anteriores, modelando de forma eficaz a natureza sequencial das informações de entrada [59].

Esses ciclos são formados por conexões entre os neurônios, possibilitando a transmissão de feedback dentro da rede e a criação de uma memória interna. Tal mecanismo facilita o aprendizado de correlações temporais, já que permite que a informação flua de forma recorrente entre diferentes etapas da sequência. Esses ciclos podem ser utilizados em qualquer ponto e direção da rede, proporcionando flexibilidade na modelação de sequências [60].

Entretanto, as RNNs tradicionais enfrentam limitações, como a dificuldade em capturar dependências de longo prazo devido ao problema do desvanecimento ou explosão do gradiente. Essas limitações motivaram o desenvolvimento de arquiteturas mais avançadas, como as Redes de Memória de Longo Prazo (Long Short-Term Memory – LSTM), que lidam de forma mais eficiente com tais desafios [59].

A LSTM é um tipo de RNN particularmente eficaz no modelamento de dados sequenciais, destacando-se pela sua capacidade de aprender dependências de longo prazo. Sua arquitetura é composta por componentes interconectados, incluindo portas de entrada, esquecimento e saída, responsáveis por regular o fluxo de informações ao longo da rede, como mostrado na Figura 2.4.

A porta de esquecimento determina quais informações serão descartadas da célula de memória, eliminando dados irrelevantes para a previsão atual. Essa decisão é baseada no estado oculto anterior e na entrada atual, como mostrado na equação:

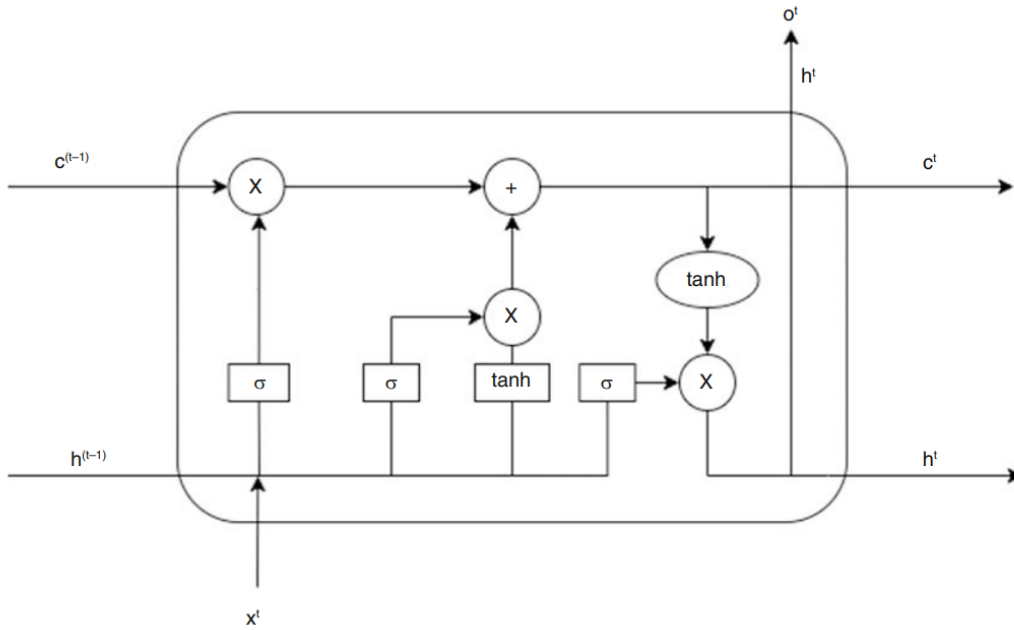


Figura 2.4: Esquemático de uma Célula LSTM [59].

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.2)$$

Onde:

- f_t : valor da porta de esquecimento (entre 0 e 1);
- h_{t-1} : estado oculto da etapa anterior;
- x_t : entrada atual;
- W_f, b_f : pesos e viés associados à porta de esquecimento;
- σ : função sigmoide.

O valor f_t é multiplicado pelo estado de memória anterior C_{t-1} , determinando quais informações serão mantidas.

A porta de entrada define quais novas informações serão adicionadas à memória da célula. Esse processo envolve duas etapas: calcular os candidatos à nova memória e determinar quanto deles será incorporado. As equações são:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.3)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (2.4)$$

Onde:

- i_t : valor da porta de entrada;
- \tilde{C}_t : candidatos à nova memória;
- W_i, W_C, b_i, b_C : pesos e vieses;
- σ : função sigmoide;
- \tanh : função tangente hiperbólica.

A atualização do estado de memória da célula é realizada por meio da combinação entre as portas de esquecimento e de entrada:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (2.5)$$

A porta de saída controla qual parte do estado da célula será utilizada como saída e também define o novo estado oculto h_t , que será propagado para a próxima célula da rede. As equações que modelam esse processo são:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.6)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (2.7)$$

Onde:

- o_t : valor da porta de saída;

- h_t : novo estado oculto;
- $\tanh(C_t)$: estado de memória filtrado.

Cada porta processa a entrada atual x_t e o estado oculto anterior h_{t-1} por meio de transformações lineares seguidas de funções de ativação não lineares (sigmoide ou tangente hiperbólica). O valor resultante (entre 0 e 1) indica a proporção de informação que será armazenada, esquecida ou propagada.

Essa combinação de portas e mecanismos de controle confere às redes LSTM a capacidade de capturar dependências de longo prazo, tornando-as especialmente eficazes em aplicações que envolvem o processamento de sequências extensas, como previsão de séries temporais e processamento de linguagem natural [61].

Capítulo 3

Materiais e Métodos

Esta tese de mestrado teve por objetivo desenvolver um modelo de previsão da geração de energia eólica para o horizonte de curto prazo com intervalos de uma hora. Para tal, foi utilizada uma abordagem com redes neurais, com modelos MLP, LSTM Univariável e LSTM Multivariável.

Este capítulo aborda a metodologia aplicada durante o desenvolvimento do trabalho, incluindo a descrição da base de dados utilizada, o desenvolvimento de diferentes modelos preditivos e as métricas escolhidas para validação.

Para a arquitetura Perceptron Multicamadas (MLP) foram definidas diferentes configurações com variações nas técnicas empregadas, na quantidade de camadas e na quantidade de neurónios. Onze modelos com essas variações foram testados afim de encontrar a versão mais adequada para o problema.

Para a arquitetura Long Short-Term Memory (LSTM) foram desenvolvidos dois modelos principais: um modelo univariado foi criado para avaliar o resultado utilizando apenas o histórico de geração média de energia eólica. Um segundo modelo foi projetado para receber múltiplas entradas, incluindo as variáveis do ambiente em que a turbina está instalada, e gerar a previsão dos valores futuros de geração média de energia eólica da turbina.

Neste capítulo também são apresentados, justificados e explicados os métodos de avaliação utilizados. São definidas as métricas de erro utilizadas e destaca-se um breve

panorama global relacionado a métrica de Raiz do Erro Quadrático Médio (RMSE).

3.1 Base de Dados

Esta seção é focada em todo o processo envolvendo os dados utilizados nos modelos preditivos. Ela descreve as etapas de coleta dos dados, o tratamento necessário para remover valores *outliers*, a decomposição sazonal realizada para identificar padrões e o pré-processamento para a entrada na rede neuronal.

3.1.1 Coleta de dados

Para esta pesquisa foram utilizados dados reais de produção de energia eólica, disponibilizados pela empresa Energias de Portugal (EDP). Os conjuntos de dados foram retirados de uma plataforma online de acesso aberto [62] e beneficiam de uma licença CC-BY-SA de utilização livre.

O Controle de Supervisão e Aquisição de Dados (SCADA) é um sistema padrão, com sensores instalados em turbinas eólicas, que normalmente regista dados padrões, médias, mínimos e máximos em um intervalo de 10 minutos [63].

A fonte utilizada fornece conjuntos de dados SCADA de quatro turbinas eólicas coletados de 1º de janeiro de 2016 a 31 de dezembro de 2017. São fornecidos quatro arquivos para cada ano: um registo do histórico de falhas, um registo de status, um conjunto de dados da torre meteorológica e um conjunto de dados registados das turbinas eólicas, totalizando oito arquivos.

Para o objetivo deste estudo, apenas o arquivo contendo dados das turbinas foi usado. Este arquivo tem registos de 83 variáveis com a periodicidade de 10 minutos, incluindo o identificador da turbina, o registo de data/hora e 81 variáveis relacionadas às condições ambientais e às condições da turbina. As variáveis ambientais incluem velocidade do vento, temperatura ambiente e direção do vento, enquanto as variáveis de condições da turbina incluem temperatura do componente da turbina, velocidade dos componentes rotativos e potência ativa. Algumas das variáveis estão associadas ao mesmo atributo




Figura 3.1: Série Temporal da energia média produzida entre 2016 e 2017.

físico e adicionalmente fornecem estatísticas diferentes, por exemplo, tem-se a média, o mínimo, o máximo e o desvio padrão da velocidade do vento ambiente.

O local exato de instalação e especificações técnicas da turbinas não são descritos. Sabe-se apenas que o modelo da turbina tem potência nominal de 2 megawatts (MW) com uma caixa de engrenagens composta por três estágios, sendo os primeiros planetários e o último de engrenagens retas (spur).

3.1.2 Tratamento de dados

Os dados foram tratados para utilizar apenas os valores da turbina T01 para evitar a introdução de variáveis adicionais que poderiam afetar a homogeneidade dos dados, como diferenças operacionais, de manutenção ou de condições de instalação entre as turbinas. Os resultados foram salvos em dois arquivos CSV, representando os anos de 2016 e 2017. A série temporal pode ser visualizada na Figura 3.1.

Para melhor visualização, foi gerado um gráfico da série temporal considerando apenas o mês de janeiro de 2016, como mostrado na Figura 3.2. Nessa Figura, é possível perceber que a geração de potência não é contínua. Há vários períodos de produção intensa seguidos




Figura 3.2: Série Temporal da energia média produzida em Janeiro de 2016.

de quedas bruscas para quase zero. Alguns dias apresentam picos que chegam a cerca de 2000 W, a qual representa a capacidade máxima que a turbina pode produzir.

Existem diversos trechos em que a potência média é praticamente nula, o que pode indicar que a velocidade do vento está abaixo da velocidade de corte inicial ou que os ventos estão com velocidade acima da do valor de corte final e a turbina foi desligada para evitar danos à estrutura ou ainda, pode representar desligamentos para manutenção e falhas operacionais.

3.1.3 Decomposição Sazonal

A decomposição sazonal é um passo geralmente realizado ao trabalhar com séries temporais. É um método útil para uma análise exploratória da série, permitindo identificar padrões e preparar os dados para modelos preditivos mais avançados.

Este procedimento decompõe a série em uma componente sazonal, uma componente combinada de tendência/ciclo e uma componente residual. Primeiro, a tendência é estimada aplicando um filtro de convolução aos dados. A tendência é removida da série e a média sem tendência para cada período é a componente sazonal retornada.




Figura 3.3: Decomposição da Série Temporal de Janeiro de 2016 a Dezembro de 2017 em Componentes de (a) Tendência, (b) Sazonalidade e (c) Residual.

A série temporal da energia média produzida foi submetida a decomposição sazonal. Para isso, foi utilizada a função `seasonal_decompose` da biblioteca `StatsModels`, em que a decomposição é feita por meio de médias móveis e pode ser realizada de forma aditiva ou multiplicativa. Os resultados são mostrados na Figura 3.3.

A componente de tendência representa a média suavizada da energia gerada ao longo do tempo e, portanto, não possui valores negativos.

A componente sazonal separa padrões repetitivos, neste caso, ciclos diários. Como a decomposição é centrada na média, os valores oscilam em torno de zero. Valores positivos indicam que, naquele momento, a energia gerada está acima da média e valores negativos indicam que a energia gerada está abaixo da média.

A componente residual representa o ruído ou variações imprevisíveis nos dados após a




Figura 3.4: Decomposição da produção média em janeiro de 2016 como (a) tendência, (b) sazonal e (c) componente residual.

remoção da tendência e sazonalidade. Valores negativos indicam que a energia gerada em um momento específico foi menor do que o esperado pelo modelo. Isso pode ser devido a fatores inesperados, como falhas de turbinas, mudanças climáticas repentinas ou erros de medição de sensores.

Para uma melhor visualização das características da série temporal, a decomposição sazonal também foi realizada para janeiro de 2016, conforme mostrado na Figura 3.4.

Analisando a Figura 3.4a, é possível observar que a tendência apresenta picos e vales ao longo do mês, refletindo mudanças graduais nas condições de vento.

A Figura 3.4b mostra um padrão repetitivo e regular diário, com ciclos bem definidos ao longo dos dias do mês. Isso indica que a geração de potência eólica segue um comportamento sazonal previsível, possivelmente relacionado a variações diárias do vento.

A Figura 3.4c representa os resíduos com flutuações rápidas e aparentemente aleatórias, sugerindo a presença de ruído ou eventos imprevisíveis na série, como mudanças bruscas nas condições do vento.

Portanto, a decomposição revelada na Figura 3.4 demonstra um componente sazonal forte com padrão diário. Com base nisso, foi definida como entrada para as redes neuronais o conjunto de 24 horas, ou seja, 144 amostras, como será descrito de forma aprofundada nas seções seguintes.

3.1.4 Seleção de Variáveis para Entrada na Rede Neural

A seleção das variáveis de entrada é uma das etapas mais importantes ao desenhar uma solução utilizando redes neuronais. Nesse processo, deve-se selecionar as variáveis mais relevantes e que agreguem informação para a rede. Para uma seleção de variáveis bem sucedida, o foco deve ser encontrar as colunas que sejam mais pertinentes em relação a variável-alvo e evitar variáveis redundantes que apenas aumentam a complexidade da rede sem acrescentar novas informações.

Em casos com muitas variáveis de entrada, pode ocorrer o problema de overfitting, em que a rede acaba ajustando de forma excessiva, deixando de ignorar os ruídos dos dados. Um modelo excessivamente ajustado perde a capacidade de generalização e pode apresentar previsões imprecisas. Uma forma de avaliar se a rede neuronal está com sobreajuste é comparar as métricas entre os conjuntos de treino e teste, por exemplo, o coeficiente R^2 . Se os valores no treino são consideravelmente superiores ao conjunto de teste pode ser um indicio de sobreajuste do modelo e deve-se considerar melhorar a validação dos dados.

Outro ponto é que com excessivas variáveis de entrada aumenta a complexidade para interpretação do sistema, com maior dificuldade para analisar a significância de cada entrada sobre a previsão.

Para escolher adequadamente as variáveis de entrada, o primeiro passo foi analisar a Equação 2.1 da máxima potência de uma turbina eólica, definida na seção 2. Nessa equação, a relação cúbica entre a velocidade do vento e a potência da turbina, indica

que variações pequenas na velocidade do vento podem gerar mudanças significativas na produção de energia. Assim, a velocidade do vento constitui-se em uma variável altamente influente e necessária para prever com precisão os valores da potência média gerada, refletindo diretamente as condições ambientais que afetam o desempenho da turbina.

Outro método utilizado para a decisão adequada foi uma matriz de correlação. Essa ferramenta apresenta as correlações entre todos os pares de variáveis, baseando-se em princípios de estatística e é amplamente utilizada.

Em uma matriz de correlações, os elementos na diagonal principal são sempre iguais a 1, pois representa a interconexão da própria variável, e a matriz é sempre simétrica na diagonal. A medida utilizada na matriz é denominada coeficiente de correlação (r). Ela mede o valor e a direção da relação linear entre duas variáveis [64].

- Se $r > 0$, as duas variáveis tendem a variar no mesmo sentido, com a maior correlação representada por 1, seja para crescimento ou decréscimo.
- Se $r < 0$, as duas variáveis tendem a variar em sentido negativo, apresentando uma relação inversa, com a maior correlação representada por -1.
- Se o valor do coeficiente for zero ou próximo de zero, as variáveis não têm uma correlação muito forte, ou a relação não é linear.

Na Figura 3.5 são mostrados os resultados da matriz de correlação aplicadas as variáveis da base de dados em análise. A visualização é um *heat map*, em que as variáveis com cores vermelhas apresentam maior correlação positiva com a variável produção de energia, variáveis com cores mais azuladas apresentam maior correlação negativa e variáveis com cores cinza representam correlação próxima de zero ou inexistente.

Devido a grande quantidade de variáveis na base de dados, foram filtradas apenas as variáveis com correlação $r > 0,45$. As colunas com maior correlação são apresentadas em cor vermelho escuro, enquanto as menos correlacionadas estão com tonalidade mais clara.

Com esse método percebe-se as dez variáveis que apresentam maior correlação positiva com a série de potência média gerada, como apresentado na tabela 3.1. Os valores de correlação variam desde 0,6188 a 0,8592.

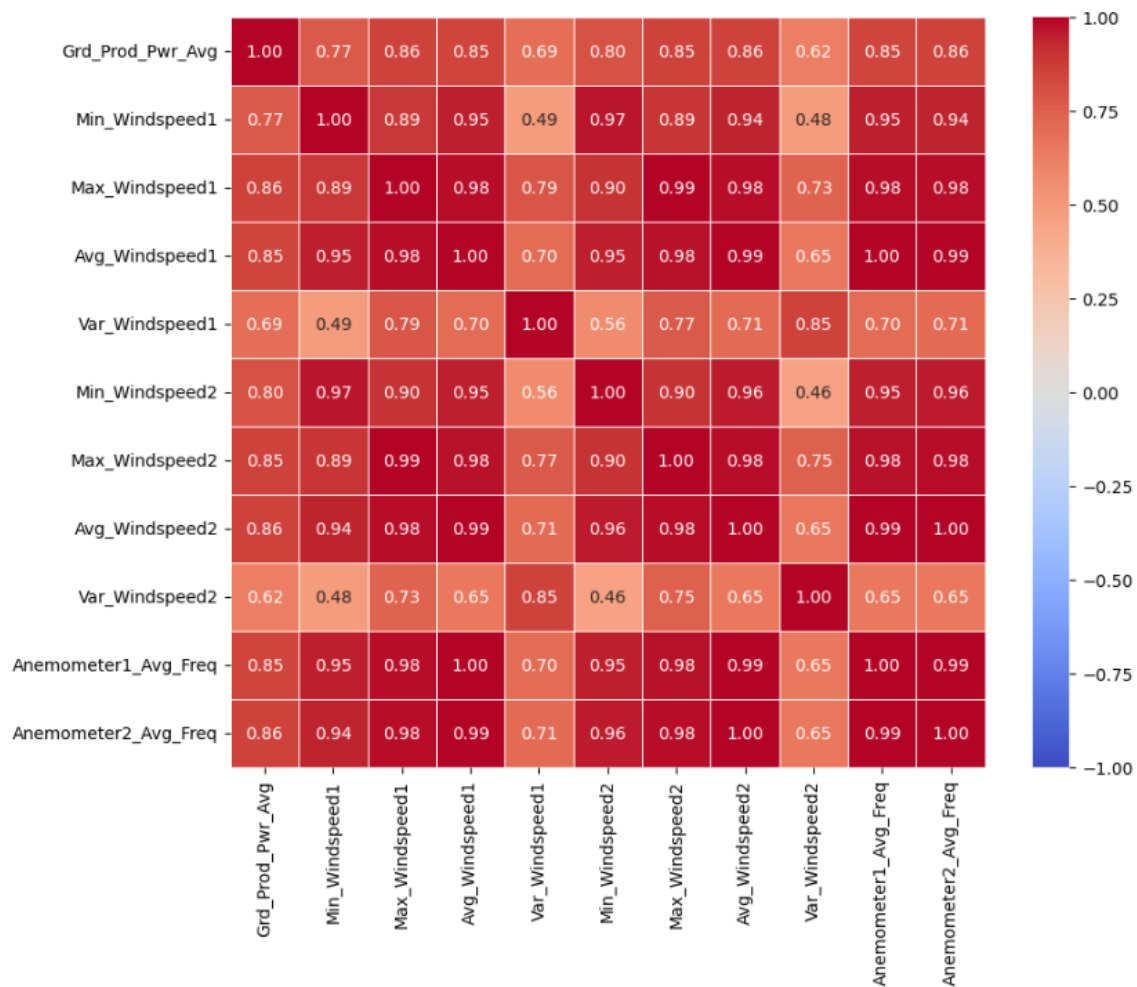


Figura 3.5: Heat-map de correlação entre as variáveis do conjunto de dados.

Tabela 3.1: Variáveis com maior correlação positiva com a potência média gerada.

Variável	Valor de Correlação
Max_Windspeed1	0.8591
Anemometer2_Avg_Freq	0.8550
Avg_Windspeed2	0.8550
Max_Windspeed2	0.8550
Avg_Windspeed1	0.8494
Anemometer1_Avg_Freq	0.8494
Min_Windspeed2	0.8020
Min_Windspeed1	0.7703
Var_Windspeed1	0.6946
Var_Windspeed2	0.6188

Além da matriz de correlações e da Equação 2.1, também foi considerada a utilização de dados históricos da própria variável de potência média produzida. Essa escolha justifica-se pela forte dependência temporal observada em séries temporais de geração de energia e permite explorar a relação entre os valores passados e futuros da mesma variável, permitindo ao modelo capturar padrões cíclicos, tendências sazonais e comportamentos recorrentes associados à geração média de energia na rede. Incorporando essas informações históricas, o modelo de previsão pode tornar-se capaz de aprender a estrutura temporal inerente ao processo de geração, contribuindo para estimativas mais precisas.

3.2 Arquitetura MLP

Nessa seção é apresentada solução com a arquitetura MLP. A metodologia consiste em pré-processamento de dados, janelas deslizantes, treinamento e teste do modelo MLP com diferentes configurações e avaliação do modelo usando métricas de erro padrão.

A plataforma de código aberto *SkLearn* serviu como biblioteca para construção do MLP usando a linguagem de programação *Python*. Outras bibliotecas usadas incluíram *Pandas*, *NumPy*, *Matplotlib* e *Statsmodels*.

3.2.1 Pré - processamento

Uma janela deslizante foi empregada para capturar as dependências temporais em dados de energia eólica, garantindo que os padrões históricos fossem efetivamente utilizados para previsão. Cada sequência de entrada compreende 144 etapas de tempo consecutivas, representando 24 horas de dados históricos amostrados em intervalos de 10 minutos, enquanto a saída alvo consiste na hora subsequente, representada por seis registros.

A janela deslizante foi aplicada com um passo único. Para cada nova instância, a janela avança em uma única etapa de tempo, gerando sequências sobrepostas que maximizam a utilização de dados. Este processo utilizou sistematicamente segmentos de comprimento $k = 144 + 6$, onde os primeiros 144 valores servem como recursos de entrada e os últimos seis representam a saída prevista.

Este processo produziu um conjunto de dados com 100.165 casos e 150 amostras cada, abrangendo todos os pares de entrada-saída possíveis dentro dos dados disponíveis. Este conjunto de dados foi posteriormente dividido em conjuntos de treinamento, validação e teste usando diferentes taxas de divisão dependendo do cenário experimental, garantindo uma avaliação robusta do modelo MLP proposto.

O processo de normalização é importante para garantir a estabilidade numérica durante o treinamento do modelo. Esse processo também auxilia para os modelos convergirem de forma mais rápida, principalmente em modelos com pesos ajustados por gradiente.

O método utilizado foi a normalização Min-Max com intervalo definido de $[0, 1]$. A normalização Min-Max é um método de transformação linear com fórmula geral descrita pela Equação 3.1.

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (3.1)$$

Onde:

- X_n representa o valor normalizado
- X_{\min} é o valor mínimo do conjunto de dados

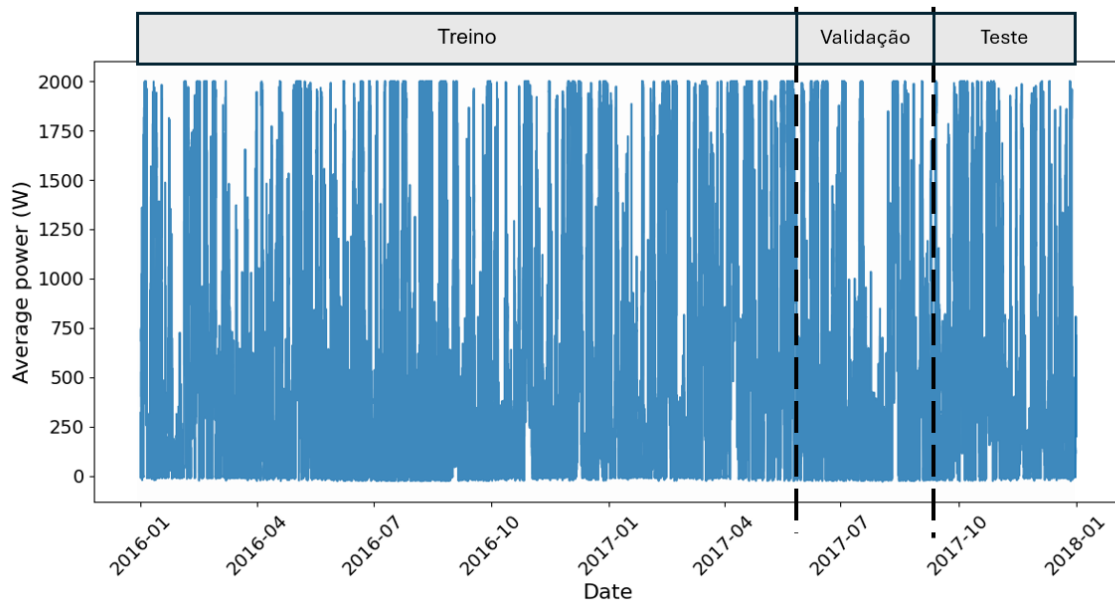


Figura 3.6: Representação da divisão dos conjuntos de treino, validação e teste na série temporal.

- X_{max} é o valor máximo do conjunto de dados
- X é o valor real ou observação original

Após a normalização, os dados foram divididos em conjuntos de treino, validação e teste, respectivamente, com 70%, 15% e 15% como mostra a Figura 3.6. Para os modelos com divisão sequencial, o conjunto de treino inicia no dia 01/01/2016 e vai até o dia 26/05/2017, seguindo para o conjunto de validação que vai até o dia 12/09/2017 e por fim, o conjunto de teste que termina em 31/12/2017.

Para os modelos que não utilizam validação, a divisão foi feita com 85% dos dados para o conjunto de treino e os restante 15% para o conjunto de teste.

3.2.2 Hiperparâmetros

Uma série de experimentos foram realizados para avaliar a sensibilidade do modelo ao número de neurónios na camada oculta variando a quantidade de neurónios de 10 a 100. A métrica MSE do conjunto de teste foi computada para cada configuração.

Os hiperparâmetros usados nos modelos MLP e os respectivos valores são mostrados na Tabela 3.2. Alguns dos parâmetros foram mantidos com o valor padrão da função para focar no impacto que diferentes arquiteturas poderiam trazer ao desempenho final.

Tabela 3.2: Hiperparâmetros para os Modelos MLP Desenvolvidos.

Parâmetros	Valor	Default
Função de Ativação	Relu	sim
Solver	Adam	sim
Alpha	1×10^{-4}	sim
Batch size	$1.00165 \times 10^{+5}$	sim
Learning rate init	1×10^{-3}	sim
Máximo de iterações	$1 \times 10^{+3}$	não
Random state	$1 \times 10^{+1}$	não
Early stopping	True	não
Validation fraction	1.764×10^{-1}	não
Beta 1	9×10^{-1}	sim
Beta 2	9.99×10^{-1}	sim
Epsilon	1×10^{-8}	sim
Tol	1×10^{-4}	sim
Batch size	$1 \times 10^{+2}$	não

3.2.3 Modelos

Diferentes configurações de redes neurais artificiais foram implementadas para avaliar o desempenho dos modelos preditivos de séries temporais propostos, variando nos métodos de particionamento de dados e no número de neurónios na camada oculta. As principais diferenças entre os modelos estão na divisão dos conjuntos de dados de treinamento, validação, teste e no design das camadas ocultas.

Os modelos que não empregaram a técnica de parada antecipada (P1 e P2) foram treinados usando uma divisão sequencial dos dados, com 85% alocados para treinamento e 15% para teste. Esses modelos foram executados por 1.000 iterações, usando uma arquitetura com uma única camada oculta contendo 50 (P1) e 25 neurónios (P2).

Além disso, os modelos que incorporam a técnica de parada antecipada (P3 a P11) usaram uma divisão de dados de três vias: 70% para treinamento, 15% para validação e

15% para teste. O mecanismo de parada antecipada foi empregado para interromper o treinamento quando o desempenho no conjunto de validação deixou de melhorar, evitando assim o overfitting.

Tabela 3.3: Resumo Descritivo dos Modelos MLP.

Modelo	Quantidade de Neurónios	Iterações	Treino, Validação e Teste
P1	50 neurónios	1000 iterações	85-0-15% (sequencial)
P2	25 neurónios	1000 iterações	85-0-15% (sequencial)
P3	50 neurónios	Early stopping	70-15-15% (sequencial)
P4	25 neurónios	Early stopping	70-15-15% (sequencial)
P5	50 neurónios	Early stopping	70-15-15% (random)
P6	25 neurónios	Early stopping	70-15-15% (random)
P7	100-50-25 neurónios	Early stopping	70-15-15% (random)
P8	50-50 neurónios	Early stopping	70-15-15% (random)
P9	200 neurónios	Early stopping	70-15-15% (random)
P10	10 neurónios	Early stopping	70-15-15% (random)
P11	75 neurónios	Early stopping	70-15-15% (random)

As arquiteturas e estratégias de divisão de dados descritas acima, com entrada de 144 parâmetros e considerando como saída os seis valores seguintes da potência média gerada, foram projetadas para avaliar o impacto de diferentes configurações de rede neural na capacidade de generalização do modelo, ao mesmo tempo em que exploram o trade-off entre complexidade e desempenho do modelo. Cada configuração foi desenvolvida para simular cenários de baixa, média e alta complexidade, considerando o número de neurónios e camadas ocultas.

3.3 LSTM com uma Variável

Para comparar o desempenho da solução com arquiteturas mais complexas, seguiu-se para uma solução utilizando redes de aprendizagem profunda. O modelo LSTM foi escolhido por ser uma arquitetura que geralmente apresenta bons resultados para entradas com séries temporais.

Para servir de referência e comparação com o modelo MLP desenvolvido anteriormente, foi desenvolvido e utilizado neste estudo um modelo LSTM com apenas uma única variável

de entrada. O intuito é avaliar o desempenho das previsões utilizando apenas os dados da série temporal que se deseja prever, ou seja, a potência média gerada, em relação ao modelo MLP e a outros modelos que empregam mais variáveis.

O pré-processamento dos dados foi realizado da mesma forma como já descrito para os modelos MLP. Em que foram selecionados os dados da turbina eólica T01 e normalizados no intervalo $[0, 1]$ utilizando a técnica `MinMaxScaler` da biblioteca `sklearn`.

Foi implementada a construção das janelas deslizantes, considerando 144 passos de entrada (correspondente a 24 horas) e 6 passos na saída (correspondente a próxima hora).

Os dados foram divididos em conjuntos de treino (70%), validação (15%) e teste (15%) de forma sequencial, sem embaralhamento, a fim de preservar a estrutura temporal dos dados.

Foram definidas cinco configurações diferentes explorando as camadas LSTM, Bidirecional e Densa. O formato dos modelos, além de levar em consideração diferentes tipos de camadas, também considerou variar a quantidade de camadas escondidas e a quantidade de neurónios em cada camada.

Um resumo dos modelos LSTM descritos nessa seção é apresentado na tabela 3.4.

Tabela 3.4: Resumo Descritivo dos Modelos LSTM com uma Variável.

Modelo	Camadas escondidas	Descrição das camadas
U1	1	LSTM com 50 neurónios
U2	2	LSTM com 100 neurónios + LSTM com 70 neurónios
U3	3	LSTM com 128 neurónios + LSTM com 64 neurónios + Densa com 24 neurónios
U4	5	Bidirecional com 100 neurónios + Dropout de 20% + Bidirecional com 100 neurónios + Dropout de 20% + Densa com 25 neurónios
U5	3	LSTM com 128 neurónios + LSTM com 64 neurónios + Densa com 24 neurónios

A primeira configuração consistiu em uma LSTM simples ("*vanilla*") com uma única camada escondida com neurónios. Essa configuração é importante para fins de comparação e referência.

Nas outras configurações utilizou-se de camadas LSTM empilhadas (*"stacked"*), ou seja, duas ou mais camadas LSTM na sequência. O objetivo com o empilhamento é formar uma rede mais profunda e explorar melhor as dependências temporais e características complexas nos dados sequenciais.

A escolha das camadas LSTM bidirecionais, cada uma com 100 unidades, com função de ativação tangente hiperbólica (\tanh), seguidas de camadas de *Dropout* com taxa de 0,2 para controle de overfitting. A saída da rede passa por uma camada densa intermediária com 25 neurónios, seguida por uma camada de saída com 6 neurónios. Com essa configuração espera-se que a rede aprenda tanto as dependências passadas quanto futuras dentro da sequência de entrada.

Todos os modelos foram treinados com o uso da técnica de *EarlyStopping*, implementada a partir da biblioteca *keras.callbacks*. Esta técnica visa interromper o treinamento automaticamente quando a métrica de validação não apresenta evolução por um número definido de épocas consecutivas, nesse caso, seis épocas. O parâmetro *restore_best_weights* garante que, ao final do treinamento, os pesos do modelo correspondam à época com melhor desempenho na validação. O uso do argumento *validation_data* durante o treinamento permite que o modelo avalie seu desempenho em dados não vistos após cada época, servindo como base para a lógica do *EarlyStopping*. Isso ajuda a evitar o sobreajuste, garantindo maior capacidade de generalização do modelo.

A função de ativação utilizada nas camadas LSTM foi a tangente hiperbólica (\tanh), escolhida por sua adequação ao contexto de séries temporais normalizadas. A função \tanh produz saídas no intervalo com uma transição mais suave dos estados ocultos ao longo do tempo. Em comparação com a função de ativação Unidade Linear Rectificada (ReLU), que não é recomendada para redes recorrentes devido ao risco de explosão de gradientes em séries longas.

O batch size selecionado foi o tamanho 256, após um treinamento avaliando a métrica Erro quadrático médio (MSE) com os valores 32, 64, 128 e 256. O resultado do treinamento é mostrado na Figura 3.7, em que é possível ver que o valor de 256 apresenta o menor valor de erro. Esse parâmetro foi aplicado a todos os modelos LSTM com entrada de




Figura 3.7: Variação do Erro Quadrático Médio (MSE) de acordo com diferentes valores de *batch size*.

variável única dessa seção.

3.4 LSTM com Múltiplas Variáveis

Foi desenvolvido também um modelo LSTM com múltiplas entradas. Esse modelo recebe diversas variáveis como entrada, incluindo variáveis meteorológicas do ambiente onde se encontra a turbina, e gera como saída apenas a potência média gerada. Esta abordagem visa capturar dependências temporais e relações não lineares entre diferentes variáveis meteorológicas e operacionais da turbina eólica.

Inicialmente, os dados brutos foram carregados a partir de arquivos CSV correspondentes aos anos de 2016 e 2017, contendo registros de operação da turbina T01 e de variáveis ambientais obtidas de uma torre meteorológica. Os dados da turbina foram filtrados para incluir exclusivamente a unidade T01, descartando a coluna identificadora por se tratar de dado categórico irrelevante para modelagem numérica.

As variáveis selecionadas do sistema SCADA da turbina compreenderam: velocidade

média do vento ambiente, potência média gerada , potência máxima e potência mínima. Do conjunto ambiental, foram extraídas as variáveis velocidade máxima do vento e frequência do anemómetro. A junção dos dois conjuntos foi realizada com base na coluna de timestamp, mantendo apenas os registros simultaneamente presentes em ambos os conjuntos (método de junção *inner*).

A seleção dessas variáveis foi realizada de acordo com os critérios definidos na seção 3, considerando a matriz de correlações, a análise da Equação da potência máxima da turbina e os dados históricos de potência média produzida pela turbina. Para a matriz de correlações, foram selecionadas apenas as variáveis com correlação acima 85%, de forma a evitar entrada excessivas.

O pré-processamento realizado foi semelhante a metodologia utilizada para os modelos LSTM de única variável descritos na seção anterior, com pequenas alterações para adaptar a estrutura das entradas e o formato dos dados. Após o pré-processamento para remoção de valores nulos e ordenação cronológica, os dados foram normalizados individualmente por meio da técnica Min-Max Scaling, com o intuito de garantir que todas as variáveis estivessem na mesma escala, o que é fundamental para a estabilidade da otimização nos modelos de redes neurais.

Para a alimentação da rede LSTM, os dados foram estruturados em janelas deslizantes. Cada entrada do modelo compreendeu uma sequência de 144 registros consecutivos (equivalente a 24 horas de dados com amostragem a cada 10 minutos), e a saída associada consistiu na previsão da potência média gerada nos seis registros subsequentes (correspondente à próxima hora). Esse procedimento foi operacionalizado por meio de uma função que criou as janelas de entrada (X) e os vetores de saída (Y), mantendo todas as variáveis disponíveis como *input*, mas considerando apenas a variável de potência média produzida como *target*.

Os dados foram divididos sequencialmente, sem embaralhamento, em conjuntos de treino (75%), validação (15%) e teste (15%).

Foram desenvolvidos e comparados cinco modelos distintos de redes LSTM.

O primeiro modelo M1 consiste em uma única camada LSTM com 50 neurónios e

função de ativação tanh, seguida por uma camada densa com 6 neurónios correspondentes ao horizonte de previsão. Essa configuração também é conhecida como LSTM *Vanilla*, devido a sua estrutura simples.

O segundo modelo M2 segue uma configuração LSTM Empilhada (*Stacked*). Nesse caso, a estrutura é composta por duas camadas LSTM sequenciais (100 e 70 unidades, respectivamente), precedendo a camada densa de saída.

O modelo M3 utilizou três camadas, com 128 e 64 unidades LSTM nas duas primeiras e uma camada densa intermediária com 24 neurónios antes da saída final.

O modelo M4 empregou camadas LSTM bidirecionais com 100 neurónios cada, intercaladas com camadas de *dropout* com taxa de 20%, e finalizadas por camadas densas com 25 e 6 neurónios.

Com o modelo M5 pretendeu-se explorar a relação da previsão com a quantidade de camadas escondidas. Por isso, foi implementada uma arquitetura com cinco camadas LSTM (20, 50, 50, 50), intercaladas com camadas densas de 20 e 6 neurónios na saída.

Todos os modelos foram otimizados com o algoritmo Adam e função de perda do erro quadrático médio (MSE). Utilizou-se Early Stopping com monitoramento da perda de validação para prevenir o sobreajuste, restaurando os melhores pesos obtidos após uma paciência de 6 épocas sem melhoria.

Na Tabela 3.5 é apresentado um resumo das configurações dos modelos propostos nessa seção.

A utilização de múltiplas variáveis de entrada na arquitetura LSTM possibilitou a incorporação de diferentes aspectos que influenciam a geração de energia, como condições meteorológicas externas e características operacionais da turbina. A abordagem adotada permitiu avaliar o impacto da complexidade da rede (número de camadas e unidades) na acurácia preditiva do sistema.

Tabela 3.5: Resumo Descritivo dos Modelos LSTM múltiplas variáveis.

Modelo	Camadas escondidas	Descrição das camadas
M1	1	LSTM com 50 neurónios
M2	2	LSTM com 100 neurónios + LSTM com 70 neurónios
M3	3	LSTM com 128 neurónios + LSTM com 64 neurónios + Densa com 24 neurónios
M4	3	Bidirecional com 100 neurónios + Dropout de 20% + Bidirecional com 100 neurónios + Dropout de 20% + Densa com 25 neurónios
M5	5	LSTM (20, 50, 50 e 50 neurónios) + Densas de 20 neurónios

3.5 Métricas de Avaliação

Os métodos de avaliação dos modelos foram definidos com base na revisão de literatura. A maioria dos trabalhos relacionados utiliza medidas estatísticas como RMSE e Erro Médio Absoluto (MAE). Com o objetivo de abranger a maior quantidade de estudos relacionados para comparação, nesse trabalho foram considerados também as métricas Erro Quadrático Médio (MSE), Raiz do Erro Quadrático Médio Normalizado (NRMSE) e o Coeficiente de determinação (R^2).

O MSE representa a diferença média entre os valores reais e previstos, onde Y_{pred} representa os valores da produção de energia eólica de acordo com o modelo de previsão, Y_{real} representa a produção real da turbina eólica e n é o número de amostras [39].

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y(t)_{pred} - Y(t)_{real})^2 \quad (3.2)$$

O RMSE é a raiz quadrada do MSE e é muito utilizado para avaliação em problemas envolvendo séries temporais. Ele representa o desvio padrão dos erros de previsão e oferece uma medida mais interpretável da magnitude do erro [65].

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y(t)_{pred} - Y(t)_{real})^2} \quad (3.3)$$

O NRMSE é semelhante ao RMSE, mas representa a porcentagem dos valores. Ele também é usado para medir a precisão do modelo de previsão, onde Y_{inst} é a capacidade instalada da turbina eólica [66].

$$NRMSE(\%) = \frac{RMSE}{Y_{inst}} \times 100\% \quad (3.4)$$

O MAE representa a magnitude média dos erros e pondera todos os valores igualmente, portanto, não adiciona nenhum peso adicional a eventos extremos de previsão [39].

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y(t)_{real} - Y(t)_{pred}| \quad (3.5)$$

O R^2 é um número entre 0 e 1 que mede o quão bem um modelo prevê um resultado [30]. Quanto melhor o desempenho do modelo, mais próximo R^2 ele está de 1.

$$R^2 = 1 - \frac{\sum_{t=1}^n (Y(t)_{real} - Y(t)_{pred})^2}{\sum_{t=1}^n (Y(t)_{real} - \bar{Y}_{real})^2} \quad (3.6)$$

A exatidão na previsão da geração de energia eólica é o principal critério para avaliar e comparar diferentes abordagens de previsão, sendo mensurada por meio de métricas específicas. Em geral, cada sistema define faixas ou padrões de desempenho para essas métricas, assegurando que o modelo preditivo atinja um nível mínimo de confiabilidade.

Operadores de sistemas de rede elétrica na China e Irlanda já definiram valores máximos de RMSE de 20% e 8%, respectivamente, como metas para previsões de curto prazo [67]. Entretanto, os valores das métricas sem a consideração do contexto em que estão inseridas, principalmente do horizonte de previsão e do tipo de abordagem utilizada (física, estatística, com redes neurais ou híbrida) podem resultar em conclusões precipitadas. As métricas de erro servem como referência para comparação de modelos [21], em que devem ser consideradas as características de cada previsão para selecionar a solução.

Capítulo 4

Resultados e Discussões

Este capítulo apresenta os resultados obtidos a partir da aplicação das arquiteturas MLP e LSTM, considerando diferentes abordagens de entrada e estratégias de particionamento dos dados.

As previsões foram realizadas com horizonte de uma hora, utilizando dados históricos de produção de uma turbina eólica e variáveis meteorológicas do ambiente da turbina, no caso dos modelos com múltiplas entradas.

A comparação entre os modelos considera as métricas definidas no capítulo 3, com foco nos valores MAE e no RMSE para efeitos de comparação com trabalhos da literatura.

4.1 MLP

Considerando os diferentes modelos comparados na Seção 3, os respectivos valores métricos foram organizados e analisados. Os resultados resumidos são mostrados na Tabela 4.1.

Todos os modelos apresentaram uma magnitude de erro alinhada com os valores de energia eólica produzida pela turbina eólica em análise.

Os melhores desempenhos foram observados nos modelos que utilizaram o particionamento aleatório dos dados com técnica de parada antecipada, especialmente o modelo P4, com arquitetura de uma camada oculta contendo 25 neurónios. O modelo P4 apresentou resultados mais consistentes com os menores valores de erro entre os modelos MLP,

Tabela 4.1: Resultados das Métricas de Erro para os Modelos MLP Desenvolvidos.

Modelo	MSE	RMSE	MAE	R²
P1	0,0142	0,1190	0,0755	0,8343
P2	0,0141	0,1186	0,0726	0,8353
P3	0,0143	0,1195	0,0731	0,8329
P4	0,0140	0,1184	0,0737	0,8359
P5	0,0154	0,1242	0,0727	0,8538
P6	0,0156	0,1248	0,0737	0,8522
P7	0,0152	0,1229	0,0723	0,8567
P8	0,0153	0,1236	0,0726	0,8551
P9	0,0149	0,1220	0,0743	0,8587
P10	0,0156	0,1249	0,0733	0,8520
P11	0,0154	0,1242	0,0732	0,8536

alcançando valores de RMSE e NRMSE inferiores aos demais.

Os modelos que empregam parada antecipada (P3-P11) demonstraram confiabilidade consistente, particularmente em cenários onde o conjunto de dados foi dividido em sub-conjuntos de treinamento, validação e teste (70%, 15% e 15%). Essa estratégia otimizou o treinamento do modelo ao evitar overfitting e garantiu generalização robusta, conforme evidenciado pelos resultados. Comparativamente, configurações sem parada antecipada (P1-P2), utilizando uma divisão de 80%-20% para treinamento e teste, mostraram desempenho competitivo, mas foram menos adaptáveis a padrões de dados variáveis.

Modelos com camadas ocultas maiores, como aqueles com 200 nós ou múltiplas camadas ocultas, exibiram precisão melhorada em conjuntos de dados de treinamento e teste. Essa melhoria destaca a capacidade de arquiteturas mais profundas de capturar relacionamentos complexos dentro dos dados.

Nas Figuras 4.1, 4.2 e 4.3 é possível visualizar em gráficos de barras a comparação dos valores de RMSE, MAE e R², respectivamente, para cada um dos modelos propostos utilizando a arquitetura MLP.

Os resultados também demonstraram que modelos com divisão de teste e treino combinada com parada antecipada (por exemplo, configurações envolvendo camadas ocultas de 50-50 neuróneos) mantiveram consistentemente alto desempenho em várias métricas, sugerindo sua adequação para cenários que exigem previsões quase em tempo real.




Figura 4.1: Resultados de RMSE para Cada Modelo Proposto MLP.




Figura 4.2: Resultados de MAE para Cada Modelo Proposto MLP.

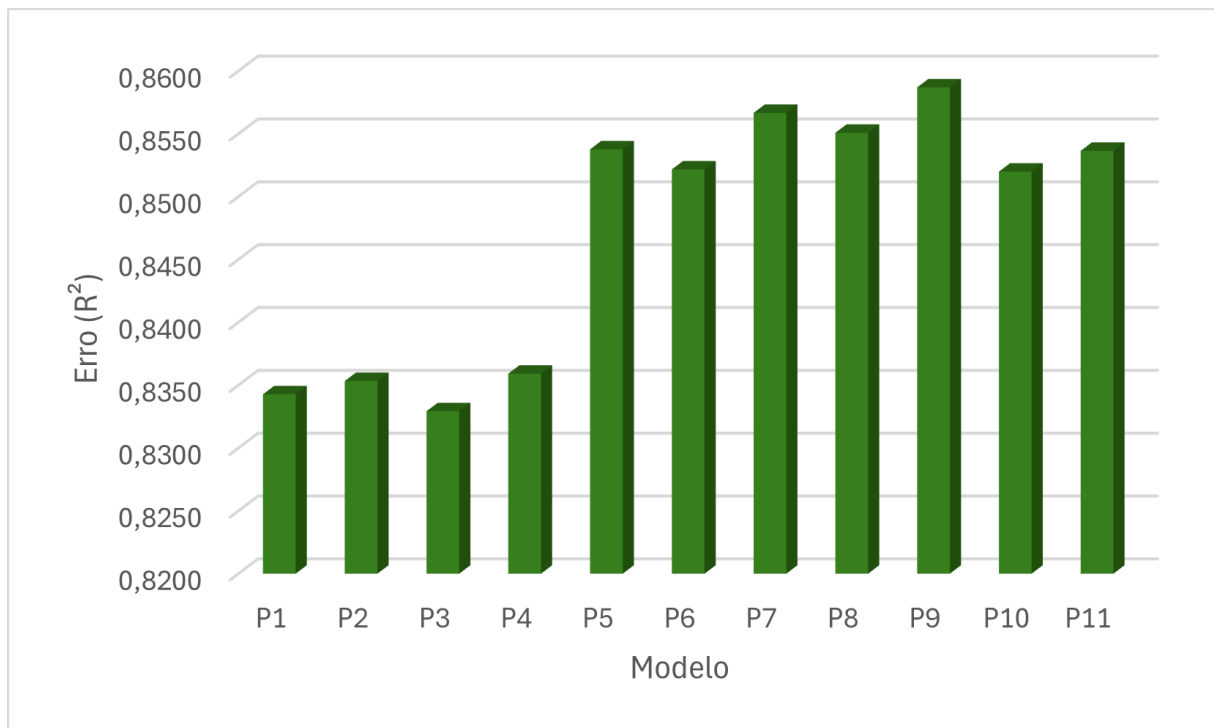


Figura 4.3: Resultados de R^2 para Cada Modelo Proposto MLP.

Embora arquiteturas complexas possam oferecer vantagens significativas em precisão, configurações mais simples combinadas com estratégias de validação eficazes, como parada antecipada, podem fornecer resultados comparáveis. Destaca-se a necessidade de alinhar a complexidade do modelo com requisitos de aplicação específicos e restrições de recursos.

Na Figura 4.4 é mostrada a sobreposição dos conjuntos de teste real e previsto, respectivamente, em azul e laranja, para o modelo P4.




Figura 4.4: Sobreposição dos conjuntos de teste real e previsto para o modelo MLP P4.

4.2 LSTM com uma variável de entrada

Com o objetivo de comparar os modelos baseados em redes recorrentes, foram desenvolvidas cinco configurações univariadas de redes LSTM, utilizando apenas o histórico da variável de saída (potência média gerada) como entrada. Os modelos variaram em quantidade de camadas e neurónios, incluindo estruturas simples com uma única camada LSTM (modelo U1) até arquiteturas com camadas bidirecionais (modelo U5).

Os resultados obtidos com os modelos LSTM com uma variável de entrada são mostrados na tabela 4.2.

Tabela 4.2: Resultados para o Modelo LSTM Univariado

Model	MSE	RMSE	MAE	R ²
U1	0,0141067	0,118772	0,075226	0,834914
U2	0,0140389	0,118486	0,0742512	0,835708
U3	0,0139861	0,118263	0,0722637	0,836326
U4	0,0139887	0,118274	0,0727753	0,836295
U5	0.014034	0,118465	0,0716025	0,835765

Os resultados mostraram que os modelos LSTM também apresentaram boa capacidade de previsão, com os valores de erro dentro da faixa esperada. Para essa arquitetura, o modelo U3, que combinou duas camadas LSTM com 50 e 25 neurónios, respectivamente, obteve o menor valor de RMSE.

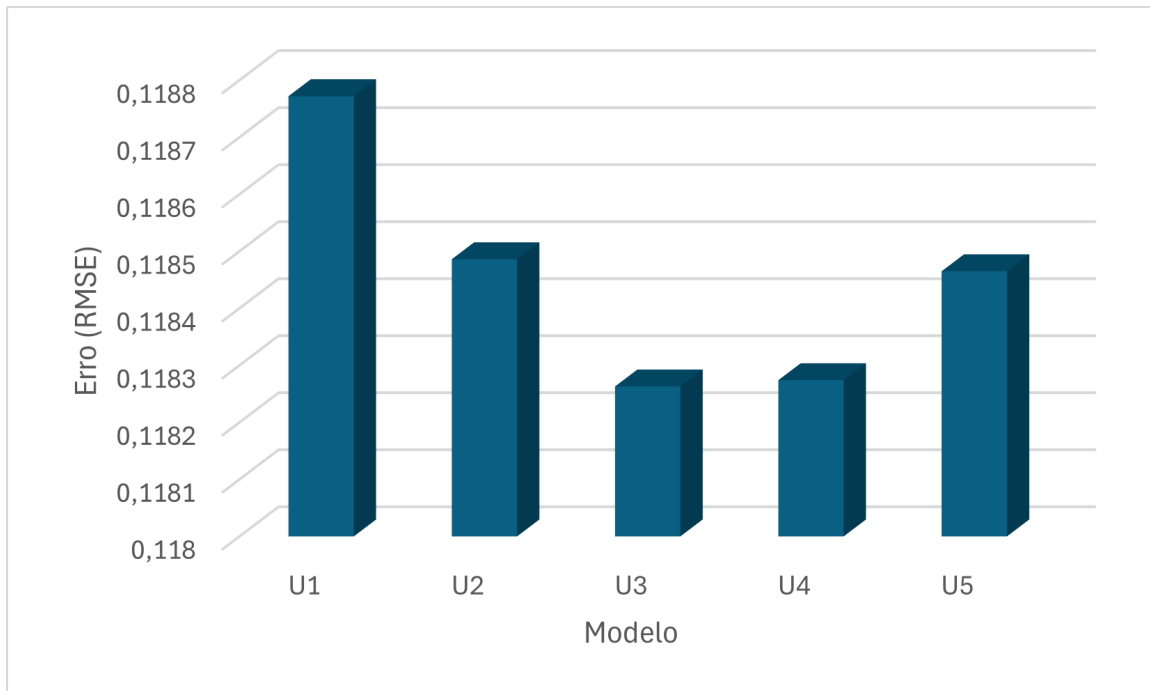


Figura 4.5: Resultados de RMSE para Cada Modelo Proposto LSTM com uma Variável na Entrada.

Nas Figuras 4.5, 4.6 e 4.7 é possível visualizar em gráficos de barras a comparação dos valores de RMSE, MAE e R^2 , respectivamente, para cada um dos modelos propostos utilizando a arquitetura LSTM com uma variável na entrada.

Na Figura 4.8 é mostrada a sobreposição dos conjuntos de teste real e previsto, respectivamente, em azul e laranja para o modelo U3. A boa sobreposição entre as duas séries evidencia que o modelo prevê os valores com acurácia satisfatória.

Mesmo com a entrada univariada, apenas a própria série temporal da potência gerada, os modelos LSTM demonstraram desempenho satisfatório na captura de padrões temporais. Percebe-se também que os modelos com mais camadas apresentaram leve tendência ao sobreajuste, exigindo cuidados adicionais com a configuração.

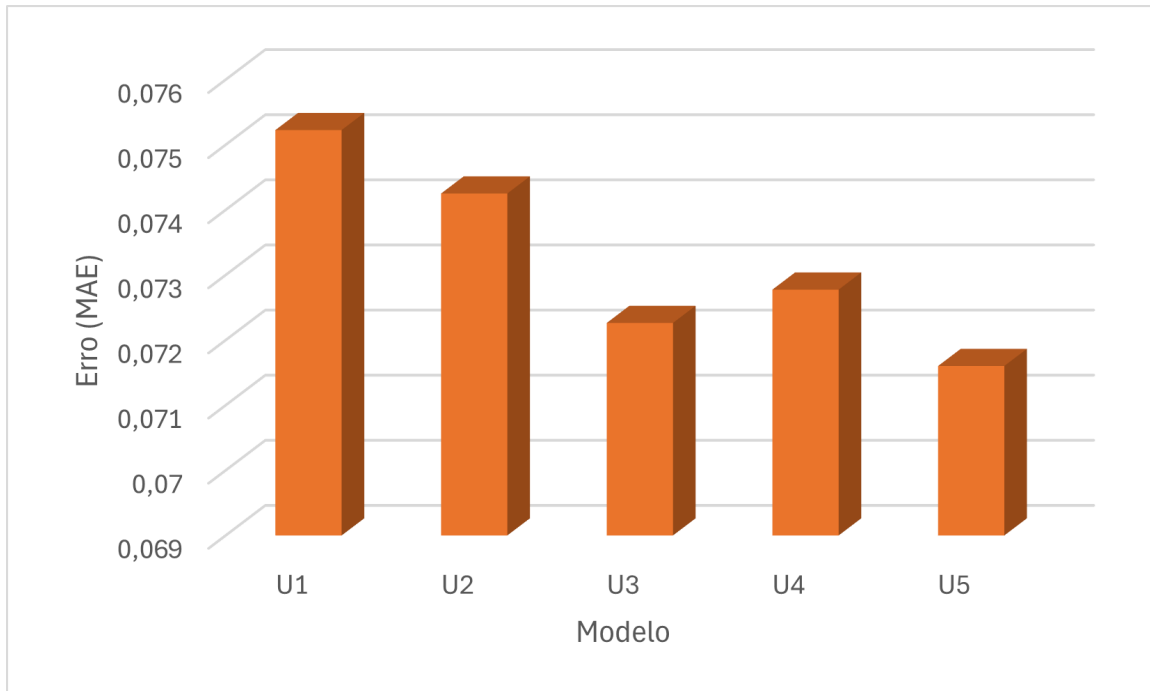


Figura 4.6: Resultados de MAE para Cada Modelo Proposto LSTM com uma Variável na Entrada.




Figura 4.7: Resultados de R^2 para Cada Modelo Proposto LSTM com uma Variável na Entrada.




Figura 4.8: Sobreposição dos conjuntos de teste real e previsto para o modelo U3 (LSTM com entrada única).

4.3 LSTM com múltiplas variáveis na entrada

A inclusão de variáveis ambientais e operacionais como entradas adicionais foi explorada nos modelos LSTM multivariáveis. As variáveis foram selecionadas com base na correlação com a potência média gerada, conforme a Tabela 3.1, incorporando informações como velocidades do vento e frequência dos anemômetros.

Os resultados obtidos com os modelos LSTM com múltiplas variáveis de entrada são mostrados na tabela 4.3.

Tabela 4.3: Resultados para o Modelo LSTM com Múltiplas Variáveis

Model	MSE	RMSE	MAE	R ²
M1	0,0135691	0,116487	0,0716885	0,849819
M2	0,0136556	0,116857	0,0717109	0,848862
M3	0,0136304	0,116749	0,072017	0,849142
M4	0,0138477	0,117676	0,071891	0,846734
M5	0,0135649	0,116469	0,0716945	0,849866

Nas Figuras 4.9, 4.10 e 4.11 é possível visualizar em gráficos de barras a comparação dos valores de RMSE, MAE e R², respectivamente, para cada um dos modelos propostos utilizando a arquitetura LSTM com múltiplas variáveis na entrada.

Entre os modelos LSTM multivariáveis desenvolvidos, destacam-se os modelos M1 e

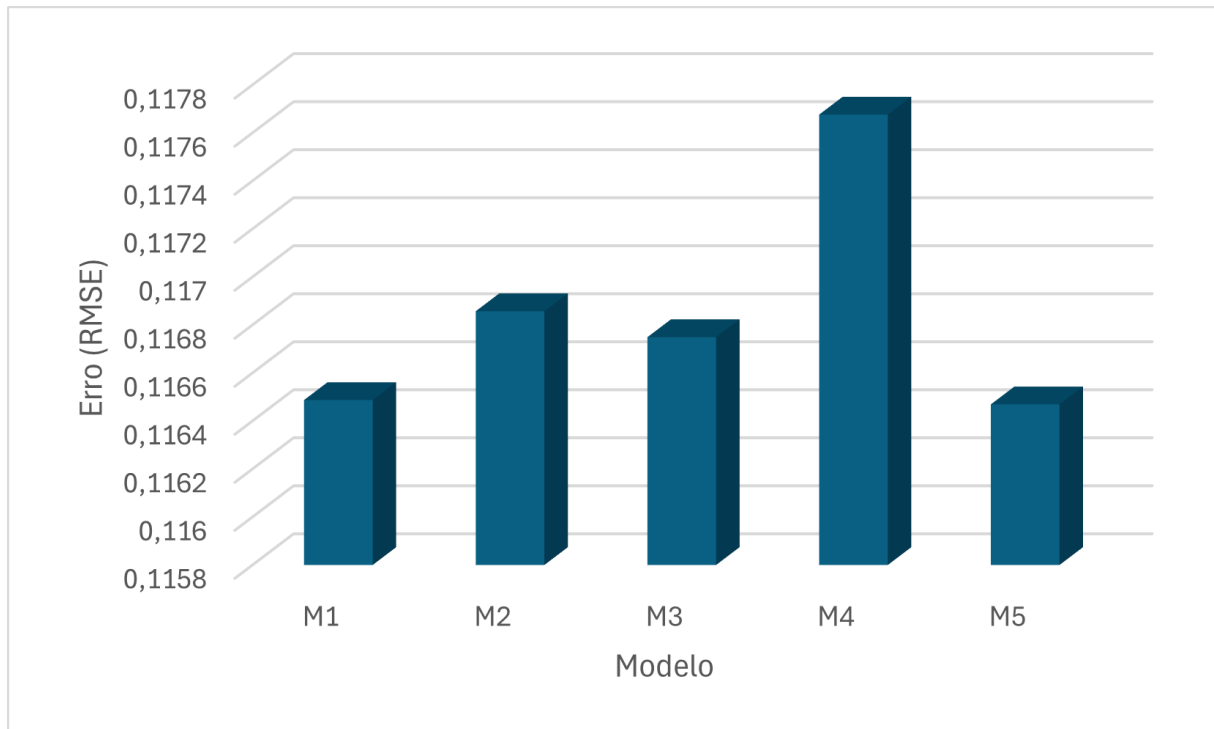


Figura 4.9: Resultados de RMSE para Cada Modelo Proposto LSTM com Múltiplas Variáveis na Entrada.

M5, que apresentaram desempenhos bastante similares no que diz respeito às métricas de avaliação aplicadas. O modelo M5, dotado de uma arquitetura mais profunda com múltiplas camadas LSTM e densas, obteve os menores valores de erro absoluto e quadrático médio (MSE e RMSE, respectivamente), evidenciando sua capacidade de modelar com boa precisão a variabilidade da série temporal de geração de potência.

Contudo, ao considerar o custo computacional associado à complexidade da arquitetura, o modelo M1 desponta como a solução mais vantajosa. Apesar de ligeiramente inferior em termos de precisão, o modelo M1 apresenta uma estrutura mais enxuta, composta por uma única camada LSTM seguida de uma camada densa, o que se traduz em menor tempo de treinamento, menor exigência de memória e maior eficiência computacional.

Esta característica é particularmente relevante em contextos operacionais onde previsões em tempo real ou com recursos computacionais limitados são necessárias. Assim,

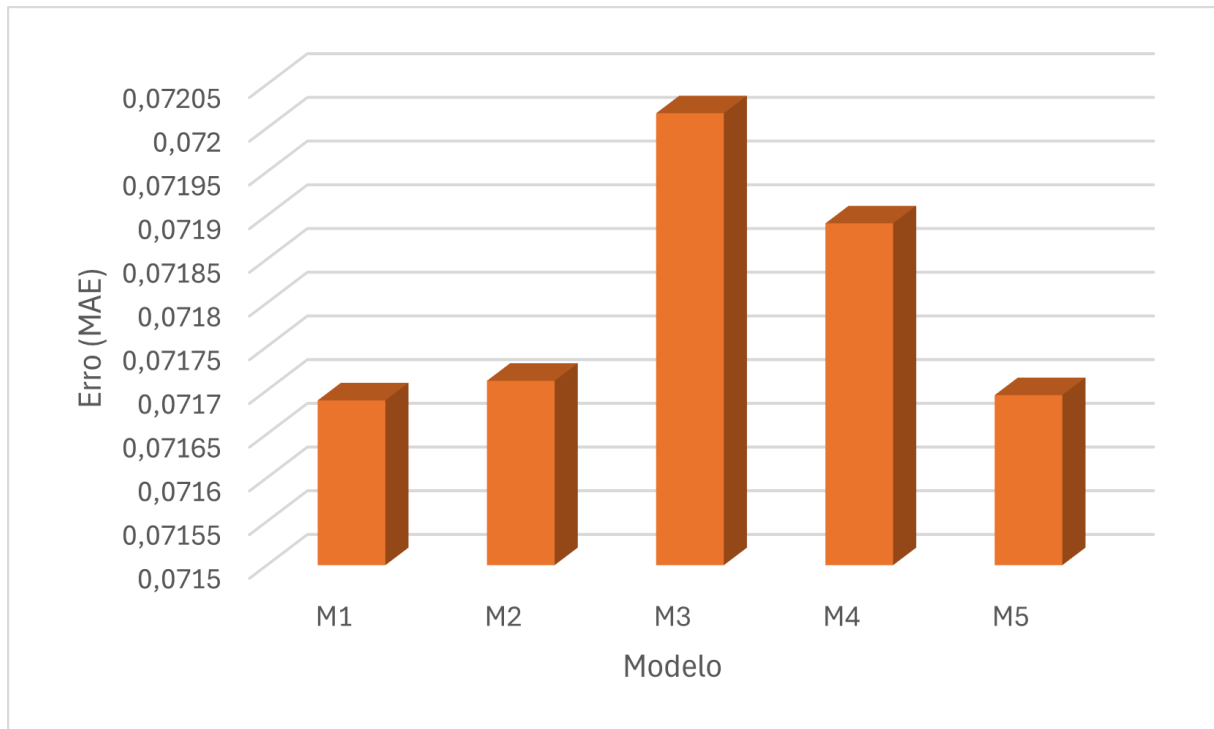


Figura 4.10: Resultados de MAE para Cada Modelo Proposto LSTM com Múltiplas Variáveis na Entrada.

ao ponderar a acurácia preditiva em conjunto com os recursos computacionais demandados, o modelo M1 representa a melhor relação custo-benefício entre todas as arquiteturas propostas, destacando-se como o mais apropriado para aplicações práticas de previsão de curto prazo da geração eólica em sistemas embarcados ou ambientes industriais com restrições de processamento.

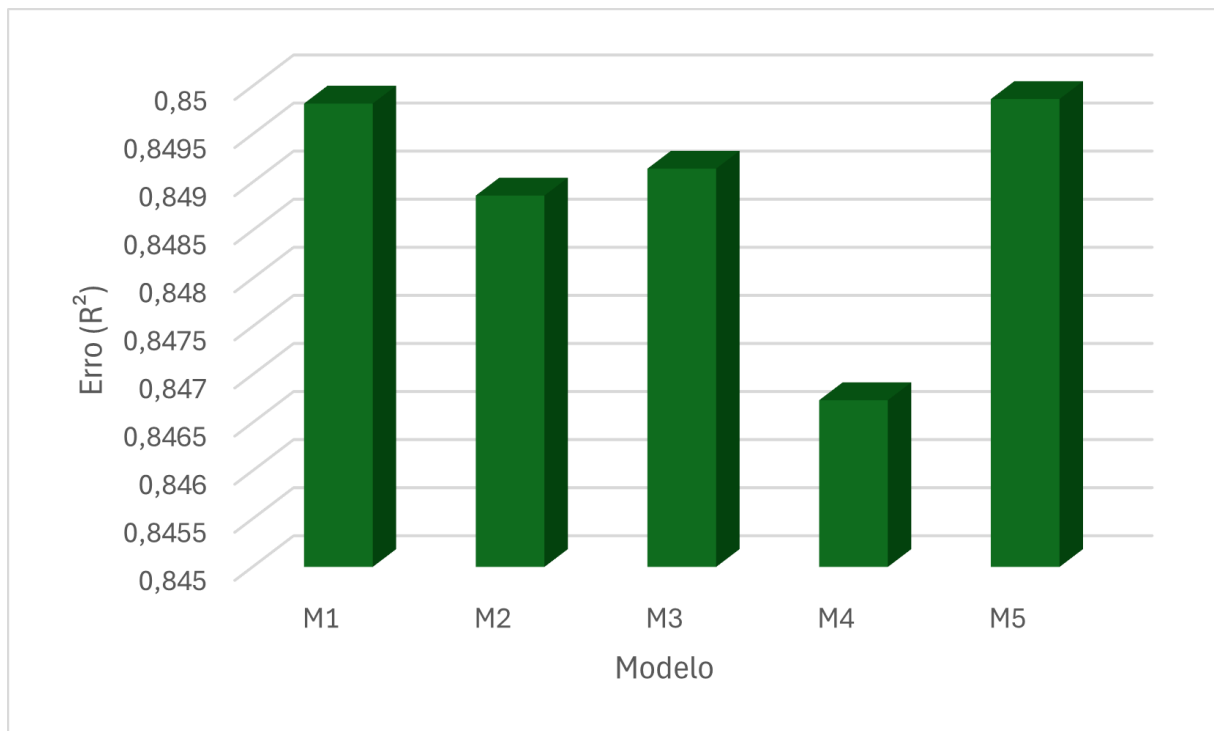


Figura 4.11: Resultados de R^2 para Cada Modelo Proposto LSTM com Múltiplas Variáveis na Entrada.

4.4 Discussão

Na tabela 4.4 é mostrada uma comparação das métricas de erro entre os melhores modelos de cada arquitetura proposta, MLP, LSTM univariado e LSTM com múltiplas entradas. Analisando esta Tabela, é possível perceber que todos os três modelos desenvolvidos apresentam um desempenho satisfatório, com coeficiente R^2 acima de 83% e RMSE abaixo de 0,12.

O modelo LSTM Multivariado proposto (M1) superou os outros dois modelos em todas as métricas avaliadas, incluindo erro médio absoluto (MAE), erro quadrático médio (RMSE) e coeficiente de determinação (R^2). Esse desempenho superior evidencia de forma clara que a incorporação de variáveis ambientais fornece ao modelo uma representação mais rica e contextualizada dos fenômenos subjacentes aos dados. Ao capturar essas influências externas, o modelo é capaz de aprender padrões temporais mais complexos e sutis, resultando em previsões mais precisas.

Em contrapartida, os modelos univariados ou com menor complexidade informacional não tem acesso a essas relações, o que compromete sua capacidade de generalização. Portanto, os resultados reforçam a importância de considerar múltiplas variáveis correlacionadas quando se busca otimizar o desempenho preditivo em séries temporais de natureza multivariada.

Tabela 4.4: Comparação entre os Resultados dos Modelos Apresentados

Modelo	MSE	RMSE	MAE	R²
MLP Proposto P4	0,0140211	0,118411	0,0737148	0,835916
LSTM Univariado Proposto U3	0,0139861	0,118263	0,0722637	0,836326
LSTM Multivariado Proposto M1	0,0135691	0,116487	0,0716885	0,849819

Na Tabela 4.5 tem-se uma comparação dos resultados desta dissertação com os de trabalhos previamente descritos na literatura. Buscou-se focar em trabalhos que realizam a previsão de curto-prazo com arquiteturas semelhantes (MLP e LSTM) e que apresentavam as métricas de erro em seus resultados.

Entre os trabalhos analisados, tem-se modelos MLP e arquiteturas híbridas CNN-LSTM. A análise ficou limitada as métricas RMSE e MAE, devido a dificuldade de encontrar modelos que tenham a descrição detalhada de todas essas métricas.

Tabela 4.5: Comparação dos Resultados dos Modelos Propostos com Trabalhos da Literatura

Modelo	MSE	RMSE	MAE	R²
MLP Proposto P4	0,0140211	0,118411	0,0737148	0,835916
LSTM Univariado Proposto U3	0,0139861	0,118263	0,0722637	0,836326
LSTM Multivariado Proposto M1	0,0135691	0,116487	0,0716885	0,849819
WF1 Persistence MLP [39]	-	0,13	0,10	-
WF2 Persistence MLP [39]	-	0,12	0,09	-
WF3 Persistence MLP [39]	-	0,18	0,15	-
WF4 Persistence MLP [39]	-	0,18	0,15	-
WF5 Persistence MLP [39]	-	0,19	0,13	-
WF6 Persistence MLP [39]	-	0,19	0,13	-
CNN-LSTM Híbrido 1 [68]	-	0,0747	0,02	-
CNN-LSTM Híbrido 2 [68]	-	0,0786	0,0103	-
CNN-LSTM Híbrido 3 [68]	-	0,1485	0,0324	-

Ao se comparar os modelos propostos com os modelos de persistência com MLP extraídos da literatura [39], verifica-se que todos os modelos próprios superam consistentemente os métodos tradicionais. Os modelos WF1 a WF6 apresentaram RMSE variando de 0,12 a 0,19, e MAE entre 0,09 e 0,15, valores maiores aos obtidos pelos modelos M1, U3 e P4.

Em relação aos modelos híbridos CNN-LSTM apresentados por [68], observa-se que a arquitetura Híbrido 1 apresentou o menor RMSE da tabela (0,0747) e MAE de apenas 0,02, sugerindo desempenho superior em termos de erro absoluto. Contudo, a ausência de valores de R^2 para essas arquiteturas impede uma comparação completa em termos da capacidade explicativa. Além disso, é importante destacar que essas arquiteturas são mais complexas, exigindo maior poder computacional e maior tempo de treinamento, o que pode ser um entrave em aplicações em tempo real ou embarcadas.

Em comparação com a literatura, percebe-se que os modelos propostos estão de acordo com o esperado, superando outros modelos com arquitetura similares, porém ainda com desempenho inferior a configurações mais complexas.

O modelo LSTM Multivariado Proposto M1 pode ser considerado a proposta mais equilibrada desta dissertação, apresentando excelente desempenho preditivo com custo computacional relativamente moderado. A combinação de variáveis ambientais relevantes e uma arquitetura recorrente simples demonstrou ser uma abordagem eficaz e robusta para a previsão de curto prazo da geração de potência eólica.

Capítulo 5

Conclusão

Esta dissertação investigou a aplicação de redes neuronais Multi-Layer Perceptron (MLP) e Long-Short Term Memory (LSTM) para previsão de energia eólica de curto prazo, utilizando dados reais de turbinas eólicas em Portugal. A metodologia proposta buscou implementar e comparar diferentes configurações de redes MLP e LSTM, com foco na acurácia da previsão.

Os resultados obtidos ao longo deste trabalho demonstram a viabilidade e a eficácia do uso de redes neuronais artificiais, em especial da arquitetura Multi-Layer Perceptron (MLP), para a previsão de curto prazo da geração de energia eólica com base em dados reais de operação. Os modelos desenvolvidos foram capazes de apresentar desempenho satisfatório, evidenciado pelos coeficientes de determinação (R^2) superiores a 83% e métricas RMSE abaixo de 0,12, destacando-se pela precisão na estimativa da geração horária com base em janelas deslizantes de 24 horas (144 amostras de entrada).

A comparação entre diferentes abordagens revelou que os modelos MLP, mesmo com estrutura relativamente simples e com entrada univariada, alcançaram desempenho competitivo em relação a modelos mais complexos, como as redes LSTM (Long Short-Term Memory). As redes LSTM univariadas mostraram resultados semelhantes, mas ligeiramente inferiores aos obtidos com a MLP. Por outro lado, os modelos LSTM com múltiplas variáveis de entrada apresentaram melhorias na acurácia preditiva, indicando que a inclusão de variáveis ambientais, como velocidade do vento, temperatura e direção do vento,

pode contribuir significativamente para o aumento da precisão das previsões.

O pré-processamento dos dados demonstrou ser um elemento fundamental para o sucesso da modelação. Etapas como a decomposição sazonal, normalização por Min-Max e a construção de janelas deslizantes permitiram ao modelo capturar padrões temporais relevantes e mitigar ruídos nos dados, aprimorando a capacidade de aprendizado das redes neuronais.

Adicionalmente, o uso de dados reais provenientes de sistemas SCADA de turbinas eólicas operando em Portugal conferiu maior robustez e aplicabilidade prática aos modelos desenvolvidos. A escolha dos dados focados em uma única turbina (T01) contribuiu para a homogeneidade dos dados e para o controle das variáveis envolvidas no processo de previsão.

Como sugestão para trabalhos futuros, recomenda-se a ampliação do conjunto de variáveis de entrada, com a inclusão de parâmetros meteorológicos adicionais, bem como a investigação de arquiteturas mais avançadas de aprendizado profundo, incluindo redes híbridas. Também é recomendável a validação dos modelos em diferentes contextos geográficos e operacionais, de forma a avaliar sua capacidade de generalização e adaptabilidade a distintos parques eólicos.

Em síntese, esta pesquisa evidencia o potencial das redes neuronais artificiais na previsão da geração de energia eólica, contribuindo diretamente para o fortalecimento da estabilidade da rede elétrica e para a integração eficiente de fontes renováveis ao sistema energético.

Bibliografia

- [1] A. De Vita, P. Capros, L. Paroussos et al., «EU Reference Scenario 2020-Energy, transport and GHG emissions Trends to 2050.,» 2021.
- [2] International Energy Agency (IEA), *IEA*, Accessed on June 13, 2024, 2023. URL: <https://www.iea.org/fuels-and-technologies/>.
- [3] C. Jung e D. Schindler, «Efficiency and effectiveness of global onshore wind energy utilization,» *Energy Conversion and Management*, vol. 280, p. 116 788, 2023.
- [4] J. Loncarski, H. A. Hussain e A. Bellini, «Efficiency, Cost, and Volume Comparison of SiC-Based and IGBT-Based Full-Scale Converter in PMSG Wind Turbine,» *Electronics*, vol. 12, n.º 2, p. 385, 2023.
- [5] S. S. Arefin, M. F. Ishraque e G. Shafiullah, «Economic Assessment of Wind Energy Compared to Other Renewable Energies,» 2023.
- [6] N. Chen, Z. Qian, I. T. Nabney e X. Meng, «Wind Power Forecasts Using Gaussian Processes and Numerical Weather Prediction,» *IEEE Transactions on Power Systems*, vol. 29, n.º 2, pp. 656–665, 2014. DOI: 10.1109/TPWRS.2013.2282366.
- [7] T. Hong, P. Pinson, Y. Wang, R. Weron, D. Yang e H. Zareipour, «Energy Forecasting: A Review and Outlook,» *IEEE Open Access Journal of Power and Energy*, vol. 7, pp. 376–388, 2020. DOI: 10.1109/OAJPE.2020.3029979.
- [8] A. Gensler, J. Henze, B. Sick e N. Raabe, «Deep Learning for solar power forecasting — An approach using AutoEncoder and LSTM Neural Networks,» em *2016*

- IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 2016, pp. 002 858–002 865. DOI: 10.1109/SMC.2016.7844673.
- [9] C. Wan, Z. Xu, P. Pinson, Z. Y. Dong e K. P. Wong, «Probabilistic Forecasting of Wind Power Generation Using Extreme Learning Machine,» *IEEE Transactions on Power Systems*, vol. 29, n.º 3, pp. 1033–1044, 2014. DOI: 10.1109/TPWRS.2013.2287871.
- [10] C. Wan, Z. Xu, P. Pinson, Z. Y. Dong e K. P. Wong, «Optimal Prediction Intervals of Wind Power Generation,» *IEEE Transactions on Power Systems*, vol. 29, n.º 3, pp. 1166–1174, 2014. DOI: 10.1109/TPWRS.2013.2288100.
- [11] D. Xu e H. Wang, «Blackout risk assessment of cascading outages considering wind power uncertainty,» em *2018 IEEE International Conference on Energy Internet (ICEI)*, IEEE, 2018, pp. 252–257.
- [12] Vaiman, Chen, Chowdhury et al., «Risk assessment of cascading outages: Methodologies and challenges,» *IEEE Transactions on Power Systems*, vol. 27, n.º 2, pp. 631–641, 2011.
- [13] P. Freitas e A. Péchy, «Espanha revela nova descoberta sobre causas de apagão que atingiu países europeus,» *VEJA*, mai. de 2025, Acesso em: 31 maio 2025. URL: <https://veja.abril.com.br/mundo/espanha-revela-nova-descoberta-sobre-causas-de-apagao-que-atingiu-paises-europeus/>.
- [14] O Globo, «O que se sabe sobre o apagão que atingiu Portugal e Espanha e o que autoridades dizem sobre possível causa,» *O Globo*, abr. de 2025, Acesso em: 31 maio 2025. URL: <https://oglobo.globo.com/mundo/noticia/2025/04/28/o-que-se-sabe-sobre-o-apagao-que-atingiu-portugal-e-espanha-e-o-que-autoridades-dizem-sobre-possivel-causa.ghtml>.
- [15] The Conversation, «Spain-Portugal blackouts: what actually happened and what can Iberia and Europe learn from it,» *The Conversation*, abr. de 2025, Acesso em: 31 maio 2025. URL: <https://theconversation.com/spain-portugal-blackouts->

what-actually-happened-and-what-can-iberia-and-europe-learn-from-it-255666.

- [16] MIT Technology Review, «Spain blackout: what happened and how to prevent it from happening again,» *MIT Technology Review*, mai. de 2025, Acesso em: 31 maio 2025. URL: <https://www.technologyreview.com/2025/05/08/1116166/spain-blackout-grid/>.
- [17] A. Ahmadpour e S. G. Farkoush, «Gaussian models for probabilistic and deterministic Wind Power Prediction: Wind farm and regional,» *International Journal of Hydrogen Energy*, vol. 45, n.º 51, pp. 27 779–27 791, 2020.
- [18] Q. P. Zheng, J. Wang e A. L. Liu, «Stochastic Optimization for Unit Commitment—A Review,» *IEEE Transactions on Power Systems*, vol. 30, n.º 4, pp. 1913–1924, 2015. DOI: 10.1109/TPWRS.2014.2355204.
- [19] Y. Ju, G. Sun, Q. Chen, M. Zhang, H. Zhu e M. U. Rehman, «A model combining convolutional neural network and LightGBM algorithm for ultra-short-term wind power forecasting,» *Ieee Access*, vol. 7, pp. 28 309–28 318, 2019.
- [20] H. Quan, D. Srinivasan e A. Khosravi, «Short-term load and wind power forecasting using neural network-based prediction intervals,» *IEEE transactions on neural networks and learning systems*, vol. 25, n.º 2, pp. 303–315, 2013.
- [21] D. B. d. ALENCAR et al., «Modelo híbrido baseado em séries temporais e redes neurais para previsão da geração de energia eólica,» 2018.
- [22] B. F. P. Ferreira, «Estudo da previsão de produção de energia eólica offshore,» tese de mestrado, Instituto Politecnico do Porto (Portugal), 2017.
- [23] M. Yang, C. Shi e H. Liu, «Day-ahead wind power forecasting based on the clustering of equivalent power curves,» *Energy*, vol. 218, p. 119 515, 2021, ISSN: 0360-5442. DOI: <https://doi.org/10.1016/j.energy.2020.119515>. URL: <https://www.sciencedirect.com/science/article/pii/S0360544220326220>.

- [24] E. Dupont, R. Koppelaar e H. Jeanmart, «Global available wind energy with physical and energy return on investment constraints,» *Applied Energy*, vol. 209, pp. 322–338, 2018.
- [25] F. Coelho, F. Silva, C. Goncalves, R. Bessa e A. Alonso, «A Blockchain-based Data Market for Renewable Energy Forecasts,» em *2022 Fourth International Conference on Blockchain Computing and Applications (BCCA)*, 2022, pp. 297–304. DOI: 10.1109/BCCA55292.2022.9922150.
- [26] M. H. Athari e Z. Wang, «Impacts of wind power uncertainty on grid vulnerability to cascading overload failures,» *IEEE Transactions on Sustainable Energy*, vol. 9, n.º 1, pp. 128–137, 2017.
- [27] G. Xu, Y. Chen, G. Ma, X. Zhao, R. Ju e J. Wang, «Study on Early warning of cascading failure for power grid considering wind power integration,» em *IOP Conference Series: Materials Science and Engineering*, IOP Publishing, vol. 199, 2017, p. 012018.
- [28] Ambiente Online, «Apagão pode ter provocado perdas de 2 mil milhões de euros nas empresas portuguesas, revela inquérito da AIP,» *Ambiente Online*, mai. de 2025, Acesso em: 31 maio 2025. URL: <https://www.ambienteonline.pt/podcasts/apagao-pode-ter-provocado-perdas-de-2-mil-milhoes-de-euros-nas-empresas-portuguesas-revela-inquerito-da-aip>.
- [29] G. Marulanda, J. Cifuentes, A. Bello e J. Reneses, «Short-term wind power forecasting by a long short term memory ensemble approach,» em *2022 13th International Renewable Energy Congress (IREC)*, IEEE, 2022, pp. 1–6.
- [30] Y. Chen, X. Hu e L. Zhang, «A review of ultra-short-term forecasting of wind power based on data decomposition-forecasting technology combination model,» *Energy Reports*, vol. 8, pp. 14200–14219, 2022.

- [31] E. Ahn e J. Hur, «A short-term forecasting of wind power outputs using the enhanced wavelet transform and arimax techniques,» *Renewable Energy*, vol. 212, pp. 394–402, 2023.
- [32] T. Bashir, H. Wang, M. Tahir e Y. Zhang, «Wind and solar power forecasting based on hybrid CNN-ABiLSTM, CNN-transformer-MLP models,» *Renewable Energy*, vol. 239, p. 122 055, 2025.
- [33] K. Rohrig e B. Lange, «Application of wind power prediction tools for power system operations,» em *2006 IEEE Power Engineering Society General Meeting*, IEEE, 2006, 5–pp.
- [34] A. Eicke, L. Eicke e M. Hafner, «Wind Power Generation,» em *The Palgrave Handbook of International Energy Economics*, Springer International Publishing Cham, 2022, pp. 171–182.
- [35] S. Muyeen, J. Tamura e T. Murata, *Stability augmentation of a grid-connected wind farm*. Springer Science & Business Media, 2008.
- [36] H. Liu, C. Chen, X. Lv, X. Wu e M. Liu, «Deterministic wind energy forecasting: A review of intelligent predictors and auxiliary methods,» *Energy Conversion and Management*, vol. 195, pp. 328–345, 2019, ISSN: 0196-8904. DOI: <https://doi.org/10.1016/j.enconman.2019.05.020>. URL: <https://www.sciencedirect.com/science/article/pii/S0196890419305655>.
- [37] H. Wen, P. Pinson, J. Gu e Z. Jin, «Wind energy forecasting with missing values within a fully conditional specification framework,» *International Journal of Forecasting*, vol. 40, n.º 1, pp. 77–95, 2024, ISSN: 0169-2070. DOI: <https://doi.org/10.1016/j.ijforecast.2022.12.006>. URL: <https://www.sciencedirect.com/science/article/pii/S0169207022001716>.
- [38] Y.-K. Wu e J.-S. Hong, «A literature review of wind forecasting technology in the world,» *2007 IEEE Lausanne Power Tech*, pp. 504–509, 2007.

- [39] B. Cao e L. Chang, «Development of short-term wind power forecasting methods,» em *2022 IEEE 7th Southern Power Electronics Conference (SPEC)*, IEEE, 2022, pp. 1–5.
- [40] E. Pelikan, K. Eben, J. Resler et al., «Wind power forecasting by an empirical model using NWP outputs,» em *2010 9th international conference on environment and electrical engineering*, IEEE, 2010, pp. 45–48.
- [41] D. Barbosa de Alencar, C. de Mattos Affonso, R. C. Limão de Oliveira, J. L. Moya Rodriguez, J. C. Leite e J. C. Reston Filho, «Different models for forecasting wind power generation: Case study,» *Energies*, vol. 10, n.º 12, p. 1976, 2017.
- [42] E. Yatiyana, S. Rajakaruna e A. Ghosh, «Wind speed and direction forecasting for wind power generation using ARIMA model,» em *2017 Australasian Universities Power Engineering Conference (AUPEC)*, 2017, pp. 1–6. DOI: 10.1109/AUPEC.2017.8282494.
- [43] A. More e M. Deo, «Forecasting wind with neural networks,» *Marine structures*, vol. 16, n.º 1, pp. 35–49, 2003.
- [44] A. K. Mishra e L. Ramesh, «Application of neural networks in wind power (generation) prediction,» em *2009 International Conference on Sustainable Power Generation and Supply*, IEEE, 2009, pp. 1–5.
- [45] Z. Liu, W. Gao, Y.-H. Wan e E. Muljadi, «Wind power plant prediction by using neural networks,» em *2012 IEEE energy conversion congress and exposition (ECCE)*, IEEE, 2012, pp. 3154–3160.
- [46] Y. V. Makarov, C. Loutan, J. Ma e P. De Mello, «Operational impacts of wind generation on California power systems,» *IEEE transactions on power systems*, vol. 24, n.º 2, pp. 1039–1050, 2009.
- [47] R. Ak, O. Fink e E. Zio, «Two machine learning approaches for short-term wind speed time-series prediction,» *IEEE transactions on neural networks and learning systems*, vol. 27, n.º 8, pp. 1734–1747, 2015.

- [48] A. Lazcano, M. A. Jaramillo-Morán e J. E. Sandubete, «Back to basics: The power of the multilayer perceptron in financial time series forecasting,» *Mathematics*, vol. 12, n.º 12, p. 1920, 2024.
- [49] A. P. Marugán, F. P. G. Márquez, J. M. P. Perez e D. Ruiz-Hernández, «A survey of artificial neural network in wind energy systems,» *Applied energy*, vol. 228, pp. 1822–1836, 2018.
- [50] S. Kazmi, «A Concurrent CNN-RNN Approach for Multi-step Wind Power Forecasting,» jun. de 2024. DOI: 10.32920/26052718.v1. URL: https://rshare.library.torontomu.ca/articles/thesis/A_Concurrent_CNN-RNN_Approach_for_Multi-step_Wind_Power_Forecasting/26052718.
- [51] A. Babiker Abdalla Ibrahim e K. Altun, «LSTM Deep Learning Techniques for Wind Power Generation Forecasting,» *Journal of Soft Computing and Artificial Intelligence*, vol. 5, n.º 1, pp. 41–47, 2024. DOI: 10.55195/jscai.1471257.
- [52] K. Bhaskar e S. N. Singh, «AWNN-Assisted Wind Power Forecasting Using Feed-Forward Neural Network,» *IEEE Transactions on Sustainable Energy*, vol. 3, n.º 2, pp. 306–315, 2012. DOI: 10.1109/TSTE.2011.2182215.
- [53] Z. Qian, Y. Pei, H. Zareipour e N. Chen, «A review and discussion of decomposition-based hybrid models for wind energy forecasting applications,» *Applied energy*, vol. 235, pp. 939–953, 2019.
- [54] W. Zhang, Z. Lin e X. Liu, «Short-term offshore wind power forecasting - A hybrid model based on Discrete Wavelet Transform (DWT), Seasonal Autoregressive Integrated Moving Average (SARIMA), and deep-learning-based Long Short-Term Memory (LSTM),» *Renewable Energy*, vol. 185, pp. 611–628, 2022, ISSN: 0960-1481.
- [55] I. Khandelwal, R. Adhikari e G. Verma, «Time Series Forecasting Using Hybrid ARIMA and ANN Models Based on DWT Decomposition,» *Procedia Computer Science*, vol. 48, pp. 173–179, 2015, International Conference on Computer, Communication and Convergence (ICCC 2015), ISSN: 1877-0509.

- [56] P. O. Fernandes, J. P. Teixeira, J. J. Ferreira e S. G. Azevedo, «Modelling tourism demand: A comparative study between artificial neural networks and the Box-Jenkins methodology,» 2008.
- [57] R. Ballini, «Análise e previsões de vasos utilizando modelos de series temporais, redes neurais e redes neurais nebulosas,» tese de doutoramento, [sn], 2000.
- [58] L. Q. Nguyen, P. O. Fernandes e J. P. Teixeira, «Analyzing and forecasting tourism demand in Vietnam with artificial neural networks,» *Forecasting*, vol. 4, n.º 1, pp. 36–50, 2021.
- [59] S. Das, A. Tariq, T. Santos, S. S. Kantareddy e I. Banerjee, «Recurrent neural networks (RNNs): architectures, training tricks, and introduction to influential research,» *Machine Learning for Brain Disorders*, pp. 117–138, 2023.
- [60] R. Madan e P. S. Mangipudi, «Predicting computer network traffic: a time series forecasting approach using DWT, ARIMA and RNN,» em *2018 Eleventh International Conference on Contemporary Computing (IC3)*, IEEE, 2018, pp. 1–5.
- [61] D. Yadav, L. Sahoo, S. K. Mandal, G. Ravivarman, P. Vijayaraghavan e P. B, «Using Long Short-Term Memory Units for Time Series Forecasting,» em *2023 2nd International Conference on Futuristic Technologies (INCOFT)*, 2023, pp. 1–6. DOI: 10.1109/INCOFT60753.2023.10425756.
- [62] *EDP Open Data*. URL: <https://www.edp.com/en/innovation/open-data/data>.
- [63] G. D. N. P. Leite, A. M. Araújo e P. A. C. Rosas, «Prognostic techniques applied to maintenance of wind turbines: a concise and specific review,» en, *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 1917–1925, jan. de 2018, ISSN: 13640321. DOI: 10.1016/j.rser.2017.06.002.
- [64] R. Alves, «Aplicação de Modelos de Redes Neurais para Previsão de Consumos de Energia,» *Instituto Superior Técnico Lisboa, Dissertação para obtenção do Grau de Mestre em Engenharia Mecânica*, 2016.

- [65] Y. Ensafi, S. H. Amin, G. Zhang e B. Shah, «Time-series forecasting of seasonal items sales using machine learning—A comparative analysis,» *International Journal of Information Management Data Insights*, vol. 2, n.º 1, p. 100 058, 2022.
- [66] D. T. Viet, V. Van Phuong, M. Q. Duong, A. Kies, B. U. Schyska e Y. K. Wu, «A short-term wind power forecasting tool for vietnamese wind farms and electricity market,» em *2018 4th International Conference on Green Technology and Sustainable Development (GTSD)*, IEEE, 2018, pp. 130–135.
- [67] S. Hanifi, X. Liu, Z. Lin e S. Lotfian, «A critical review of wind power forecasting methods—past, present and future,» *Energies*, vol. 13, n.º 15, p. 3764, 2020.
- [68] M. Khan, E. A. Al-Ammar, M. R. Naeem, W. Ko, H.-J. Choi e H.-K. Kang, «Forecasting renewable energy for environmental resilience through computational intelligence,» *Plos one*, vol. 16, n.º 8, e0256381, 2021.