



Universidade Federal
do Rio de Janeiro
Escola Politécnica

Desenvolvimento de Modelo de Previsão de Geração Eólica para Planejamento Energético Utilizando Redes Neurais Artificiais

Jun Fujise

Projeto de Graduação apresentado ao Curso de Engenharia Ambiental da Escola Politécnica, Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Engenheiro.

Orientadora: Heloisa Teixeira Firmo

Rio de Janeiro
Dezembro de 2018

DESENVOLVIMENTO DE MODELO DE PREVISÃO DE GERAÇÃO EÓLICA PARA PLANEJAMENTO ENERGÉTICO UTILIZANDO REDES NEURAS ARTIFICIAIS

Jun Fujise

PROJETO DE GRADUAÇÃO SUBMETIDA AO CORPO DOCENTE DO CURSO DE ENGENHARIA AMBIENTAL DA ESCOLA POLITÉCNICA DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE ENGENHEIRO AMBIENTAL.

Examinado por:

Prof^a. Heloisa Teixeira Firmo, D.Sc.

Prof. Mauricio Tolmasquim, PhD.

Prof. Jorge Henrique Alves Prodanoff, D.Sc.

RIO DE JANEIRO, RJ – BRASIL
DEZEMBRO de 2018

Fujise, Jun

Desenvolvimento de Modelo de Previsão de Geração Eólica para Planejamento Energético Utilizando Redes Neurais Artificiais/ Jun Fujise. – Rio de Janeiro: UFRJ/ Escola Politécnica, 2018.

x, 57 p.: il.; 29,7 cm.

Orientadora: Heloisa Teixeira Firmo

Projeto de Graduação – UFRJ/ Escola Politécnica/ Curso de Engenharia Ambiental, 2018.

Referências Bibliográficas: p. 54 – 57.

1. Energia eólica. 2. Modelos de Previsão. 3. Redes Neurais Artificiais. I. Teixeira Firmo, Heloisa, orient. II. Universidade Federal do Rio de Janeiro, Escola Politécnica, Curso de Engenharia Ambiental. III. Título.

Agradecimentos

Gostaria de enviar os meus sinceros agradecimentos à professora Heloisa Teixeira Firmo, que me ajudou não só neste trabalho, mas em todos os meus 12 períodos de Fundão. Obrigado por ser sempre respeitosa e atenciosa com os alunos de Engenharia Ambiental.

Agradeço à minha família, que sempre me apoiou nestes anos em que estive fora de casa. Obrigado por todos os ensinamentos e boas energias! A presença de vocês é a coisa mais importante para mim.

Agradeço aos meus amigos do Grupo Armário: Beckinho, Champs1, Champs2 e Nervous. Sem vocês, a faculdade não seria a mesma! Obrigado pelas ótimas histórias que vivemos nestes anos.

Agradeço aos meus amigos do Rio de Janeiro, que foram a minha família do lado de cá. Obrigado também aos amigos de São Paulo, por todas as coisas boas que passamos nos últimos anos.

Gostaria de agradecer a todas as pessoas que moraram comigo nestas últimas seis residências do Rio de Janeiro. Tive muita sorte por sempre conviver com pessoas maravilhosas. Obrigado por todos os bons momentos compartilhados.

Agradeço também ao pessoal do trabalho. Esta monografia só foi possível com a ajuda de vocês, que me ensinaram tanto em apenas um ano. Obrigado por acreditarem em mim e no meu trabalho!

Resumo do Projeto de Graduação apresentado à Escola Politécnica/ UFRJ como parte dos requisitos necessários para a obtenção do grau de Engenheiro Ambiental.

Desenvolvimento de Modelo de Previsão de Geração Eólica para Planejamento Energético
Utilizando Redes Neurais Artificiais

Jun Fujise

Dezembro/2018

Orientadora: Heloisa Teixeira Firmo

Curso: Engenharia Ambiental

A geração de energia eólica teve um expressivo crescimento nas últimas décadas, atribuído aos diversos benefícios que a fonte traz para o meio ambiente e a sociedade. A expansão do modal pelo mundo e o desenvolvimento de suas tecnologias fizeram com que a operação das usinas fosse cada vez mais otimizada, tornando a eólica tão competitiva quanto outras fontes. No Brasil, a expansão expressiva nos últimos anos do parque eólico integrado ao SIN (Sistema Interligado Nacional), trouxe complexidades adicionais na operação desse sistema. Sendo assim, a previsão da geração de energia a partir de usinas eólicas apresenta importância cada vez maior para a operação otimizada do SIN. O presente trabalho buscou desenvolver um modelo de previsão de geração de energia para um parque eólico com capacidade nominal de 27,3 MW. O modelo é baseado no método das Redes Neurais Artificiais, utilizando uma arquitetura de rede do tipo *Multilayer Perceptron*. Para a avaliação do desempenho do modelo, uma análise comparativa foi feita utilizando um modelo físico e um de persistência como referência. O modelo baseado em redes neurais obteve o menor erro para todos os testes de validação, apresentando NMAPE médio igual à 9,90% para as primeiras 24 horas de previsão.

Palavras-chave: Energia Eólica, Modelos de Previsão, Redes Neurais Artificiais.

Abstract of Undergraduate Project presented to POLI/UFRJ as a partial fulfillment of the requirements for the degree of Engineer.

Development of Wind Power Prediction Model for Energy Planning Using Artificial Neural Networks

Jun Fujise

December/2018

Advisor: Heloisa Teixeira Firmo

Course: Environmental Engineering

The wind power generation had an expressive and rapid growth in the last decades, attributed to the benefits that the wind power causes to the environment and society. The worldwide expansion of the sector and its technological developments led to the optimization of the operation of the wind farms, making the wind power as competitive as other sources. Thus, production prediction models have been developed aiming to enhance the energy planning of the power plants. In Brazil, the current expansion of the wind farms within the national energy grid resulted in more complexities to the operation of the system. Therefore, the production forecast of wind farms is important to an optimized operation of the grid.

In the present study, a model was developed for a wind farm of nominal capacity of 27.3 MW. The model was based on the method of Artificial Neural Networks, using the Multilayer Perceptron as the structure of the net. To evaluate the performance of the model, a comparative analysis was made, using a physical and a persistence model as a reference. The model based on neural networks presented the lowest error to all validation tests, having an average NMAPE equals 9.90% for the first 24 hours of prediction.

Keywords: Wind Power, Prediction Models, Artificial Neural Networks.

Lista de Figuras

Figura 1. Participação das fontes de energia no SIN ao longo de 2018 até 2027. O grupo renováveis é composto por pequenas centrais hidrelétricas, biomassa, solar e eólica.....	7
Figura 2. Componentes de um aerogerador.....	8
Figura 3. Aerogerador de três pás.....	9
Figura 4. Fluxo unidirecional do vento em um aerogerador.....	11
Figura 5. Exemplo de curva de potência de um aerogerador. V_m é a velocidade mínima, V_n é a velocidade nominal e V_c é a velocidade de máxima.....	12
Figura 6. Anemômetro de copo.....	13
Figura 7. Anemômetro ultrassônico.....	14
Figura 8. NMAPE dos modelos analisados por De Giorgi, Ficarella e Tarantino (2010) para previsões de geração para até 24 horas.	20
Figura 9. Representação de um modelo de persistência para velocidade de vento. Em cima, a persistência de um modelo para uma hora à frente, embaixo, para 24 horas à frente. O dado medido (azul) gera os dados previstos (vermelho), transpondo os intervalos da amostra..	21
Figura 10. Representação esquemática do k-ésimo neurônio de uma RNA.....	22
Figura 11. Funções de Ativação.....	23
Figura 12. Estrutura de uma rede neural artificial. Cada círculo representa uma unidade de processamento.	24
Figura 13. Etapas da metodologia desenvolvida.....	31
Figura 14. Aquisição de dados utilizados nos modelos	33
Figura 15. Processos da metodologia do Modelo A	34
Figura 16. Código varrendo os históricos de dados, gerando uma série de previsão de geração H+24	35
Figura 17. Processos da metodologia do Modelo B	37

Figura 18. Função de autocorrelação de geração de energia do Parque Modelo. Cada intervalo corresponde a 1 hora. O eixo y corresponde à correlação que a geração no instante t tem com a geração no instante t mais o número de intervalos.....	41
Figura 19. Estrutura da rede escolhida. A primeira coluna corresponde aos dados de entrada (os cinco dados mais recentes e de maior correlação de vento e geração); a segunda e a terceira são as camadas ocultas; e a última é a camada de saída (previsão de geração). .	43
Figura 20. NMAPE do Modelo A por horas de previsão	44
Figura 21. RMSE do Modelo A por horas de previsão.....	44
Figura 22. Dispersão de dados de vento previsto (GFS) e verificado.....	45
Figura 23. Curva de potência representativa do Parque Modelo (vermelho) antes da aplicação do filtro.....	46
Figura 24. Curva de potência representativa do Parque Modelo (vermelho) após a filtragem de dados espúrios.....	46
Figura 25. NMAPE média diário dos Modelos A, B e C por dias de previsão	47
Figura 26. RMSE médio diário dos Modelos A, B e C por dias de previsão	48
Figura 27. Previsões H+12 dos Modelos A, B e C de 13/08/2018 a 13/09/2018. Linhas pontilhadas são as previsões e a contínua e a geração medida.	49
Figura 28. Previsões H+24 dos Modelos A, B e C de 13/08/2018 a 13/09/2018. Linhas pontilhadas são as previsões e a contínua e a geração medida.	50
Figura 29. Previsões H+50 dos Modelos A, B e C de 13/08/2018 a 13/09/2018. Linhas pontilhadas são as previsões e a contínua e a geração medida.	50
Figura 30. Previsões H+100 dos Modelos A, B e C de 13/08/2018 a 13/09/2018. Linhas pontilhadas são as previsões e a contínua e a geração medida.	51

Lista de Tabelas

Tabela 1. Capacidade instalada de energia eólica em 2017 (GWEC, 2017).	5
Tabela 2. Classificação da escala temporal de previsões eólicas (WORLD ENERGY COUNCIL, 2016).....	17
Tabela 3. Módulos do Python utilizados por etapas da metodologia	30
Tabela 4. Arranjos de parâmetros de entrada para a RNA.....	34
Tabela 5. Estruturas testadas da RNA (número de neurônios)	36
Tabela 6. Análise da performance de diferentes dados de entrada na RNA	42
Tabela 7. Análise de estruturas da RNA	42
Tabela 8. Melhora de performance utilizando o Modelo A.....	48

Sumário

1.	Introdução	1
1.1.	Objetivos	3
1.2.	Metodologia.....	3
2.1.3.	Rendimento do Aerogerador	9
2.1.4.	Curva de Potência	11
2.1.5.	Anemômetros	12
2.1.6.	Torres anemométricas	14
2.2.	Métricas de erros.....	15
2.3.	Modelos de Previsão.....	16
2.4.	Redes Neurais Artificiais	21
3.	Metodologia.....	30
3.1.	Aquisição de dados	31
3.2.	Divisão de Dados	33
3.3.	Modelo A - RNA.....	33
3.3.1.	Dados de entrada.....	34
3.3.2.	Arquitetura da RNA.....	36
3.3.3.	Avaliação do modelo	36
3.4.	Modelo B - Físico	37
3.4.1.	Ajuste linear	37
3.4.2.	Curva de Potência.....	38
3.4.3.	Conversão em Geração.....	39
3.5.	Modelo C - Persistência.....	39
3.6.	Avaliação entre Modelos	40
4.	Resultados	41
4.1.	Modelo A	41
4.2.	Modelo B	45
4.3.	Comparação entre modelos.....	47

5.	Conclusões	52
6.	Referência Bibliográfica.....	54

1. Introdução

A crescente demanda mundial por energia reflete-se no aumento da pressão global sobre o meio ambiente e seus componentes. Atualmente, as formas de obtenção do insumo são oriundas da conversão da energia potencial dos recursos ambientais em energia elétrica, e estes processos causam diversos impactos ambientais, sociais e econômicos, que devem ser avaliados a fim de minimizarem-se os impactos negativos e maximizarem-se os positivos. Assim, busca-se alinhar o conceito de desenvolvimento sustentável com o de expansão energética.

Os desenvolvimentos tecnológicos e econômicos decorrentes das revoluções industriais fizeram com que a sociedade adquirisse um modo de vida profundamente dependente da energia elétrica. O carvão foi o primeiro recurso intensamente explorado para a geração de energia, sendo este substituído pelo petróleo e gás natural posteriormente. Devido ao contexto histórico e à capacidade energética destes materiais, os combustíveis fósseis são a principal fonte de energia do mundo atualmente (BP, 2017).

Durante as últimas décadas, as altas emissões de poluentes atmosféricos provenientes da queima de combustíveis e a necessidade de uma maior segurança energética mundial geraram novas discussões sobre a diversificação do portfólio energético tradicional, visando as fontes renováveis como alternativa às fontes fósseis.

As energias renováveis são aquelas geradas a partir de processos e recursos naturais que são renovados ou reabastecidos no meio ambiente em uma escala de tempo compatível com as atividades humanas, diferentemente do petróleo, que possui taxa de reabastecimento na ordem de milhares de anos. Atualmente, destacam-se a energia hidrelétrica, eólica, solar, geotérmica e por biomassa como fontes renováveis.

A Conferência de Estocolmo, em 1972, marcou a transição da expansão das fontes renováveis de energia no mundo (GONZAGA, 2012). A reunião realizada pela Organização das Nações Unidas (ONU) tinha como objetivo promover a discussão sobre a dinâmica do desenvolvimento econômico mundial e sua degradação ambiental associada. O evento foi a primeira tentativa de fazer com que as nações incorporassem as questões ambientais em suas agendas políticas, suscitando maiores incentivos no setor das energias renováveis.

Mais recentemente, em 2015, na 21ª Conferência das Partes (COP21), o Acordo de Paris foi firmado, tentando buscar um esforço cooperativo entre os 196 países assinantes para manter o aquecimento global abaixo de dois graus Celsius (NAÇÕES UNIDAS, 2015). A meta baseia-se em programas e políticas redutoras das emissões dos gases do efeito estufa (GEEs), sendo o aproveitamento e consumo de fontes alternativas de energia uma das medidas incentivadas pelo acordo. O crescimento proporcional das renováveis, nos últimos anos, aumentou consideravelmente em relação às outras fontes (BP, 2017), e o Acordo de Paris foi um importante marco para garantir a continuação deste crescimento em um futuro próximo.

O setor eólico vem ganhando destaque nas últimas décadas, sendo uma das alternativas para a transição da dependência das energias fósseis para as energias renováveis. Em 2017, a capacidade de energia eólica mundial cresceu 53 GW, atingindo aproximadamente 540 GW instalados, sendo a China e os Estados Unidos responsáveis por 52% desta carga.

Apesar de ser considerada uma fonte renovável, a eólica também impacta negativamente o meio ambiente. Assim como qualquer projeto de grande porte, uma usina eólica também transforma o meio em que se é instalada, podendo ser danosa para os componentes ambientais e a comunidade dentro da área de influência do empreendimento. As usinas afetam ciclos migratórios de pássaros e são geradoras de ruído de baixa frequência, e, portanto, medidas preventivas devem ser tomadas a fim de reduzir-se a magnitude destes impactos.

É fato que a fonte é causadora de impactos negativos, no entanto, a eólica é considerada menos degradante para o meio ambiente do que as fontes tradicionais (petróleo, gás e carvão). A quantidade de dióxido de carbono associada à energia é mais baixa, assim, é possível avaliar o quanto de CO₂ é deixado de emitir com a substituição das fontes fósseis pela eólica. Em 2016, por exemplo, estima-se que a emissão de 637 milhões de toneladas de CO₂ foi evitada devido à operação das usinas eólicas no mundo (GWEC, 2017).

O custo de implantação e operação das usinas vem diminuindo com os avanços tecnológicos do setor. Parte deste custo está associado aos riscos financeiros intrínsecos à volatilidade e intermitência da geração eólica, que são regidas pelas variações climatológicas da região de instalação da usina. Assim, o desenvolvimento das áreas de sensoriamento, modelagem computacional, meteorologia e ciência dos dados ajuda a reduzir os riscos relativos à volatilidade dos ventos, e torna o modal mais competitivo dentro do portfólio energético.

Os modelos de previsão de vento e de geração eólica são ferramentas que aumentam a confiança na fonte renovável, diminuem os riscos financeiros e maximizam a eficiência operacional das usinas. Os modelos fornecem informações úteis para o planejamento operacional, gerando previsões de minutos até anos à frente. Com o aperfeiçoamento dos computadores, as metodologias dos modelos preditivos foram moldando-se em métodos mais complexos e acurados.

O Aprendizado de Máquina (AM) é a área de estudo que surgiu com a evolução da capacidade dos computadores, sendo muito utilizada em análises preditivas. Diversas ferramentas computacionais compõem a área de AM, pode-se citar as Redes Neurais Artificiais (RNAs), Máquinas de Vetores de Suporte e Redes Bayesianas, métodos que permitem o computador reconhecer padrões dentro de um arranjo de dados e, a partir disto, realizar tarefas específicas. Mais detalhes serão abordados nas próximas seções do presente trabalho.

1.1. Objetivos

Observando as questões expostas anteriormente e a importância que uma operação otimizada representa para a competitividade do setor eólico, o objetivo geral do presente trabalho é desenvolver e aplicar um modelo de previsão de geração eólica utilizando o método das RNAs. Espera-se que este trabalho contribua para o aumento da confiabilidade na energia eólica e para a expansão do setor no mercado energético.

Como objetivos específicos, espera-se:

- Propor uma metodologia para a aquisição e tratamento dos dados para realizar o treinamento, a validação e o teste do modelo proposto.
- Operar o modelo desenvolvido para um parque eólico real. Este objetivo avaliará a performance da metodologia, estimando-se o erro das previsões;
- Desenvolver modelos alternativos para a comparação da performance entre diferentes abordagens do problema.

1.2. Metodologia

A metodologia do presente trabalho consistiu em desenvolver três modelos de previsão de geração de energia elétrica baseados em diferentes métodos encontrados

na literatura. Primeiramente, uma pesquisa bibliográfica foi feita visando identificar o estado da arte dos modelos preditivos. Buscou-se trabalhos que fossem capazes de contextualizar os desempenhos de cada modelo em suas previsões. Em seguida, três modelos foram desenvolvidos na linguagem de programação Python 2.7, escolhida devido à facilidade em trabalhar-se com a ferramenta e ao suporte oferecido pela comunidade *online*. Em paralelo, outros programas realizaram a aquisição de dados de uma usina eólica e armazenaram em um banco de dados. Os mesmos foram utilizados como entrada dos modelos, gerando três previsões diferentes para o período analisado. Por fim, foi realizada uma análise crítica das previsões e dos modelos desenvolvidos.

1.3. Estrutura do trabalho

O trabalho está estruturado da seguinte forma: primeiramente, é apresentada uma introdução sobre a energia eólica e suas tecnologias, abordando temas como conversão energética e aquisição de dados de campo. Em seguida, é abordada uma revisão bibliográfica sobre os modelos de previsão de vento e de geração eólica, introduzindo o estado da arte e os métodos mais utilizados atualmente. Depois, uma introdução às RNAs é feita, explicando os conceitos básicos e o algoritmo em que se baseia o método. No capítulo seguinte, é apresentada a metodologia deste trabalho, e posteriormente, os resultados e conclusões.

2. Revisão Bibliográfica

Nesse capítulo, inicialmente é apresentada uma revisão bibliográfica da energia eólica e suas tecnologias. Em seguida, é feita uma introdução aos modelos de previsão no setor eólico e ao método das Redes Neurais Artificiais.

2.1. A Energia Eólica

A energia eólica é aquela oriunda do aproveitamento do deslocamento de massas de ar, havendo a conversão da cinética do vento em energia elétrica ou mecânica. Ela é explorada pela humanidade desde a antiguidade, sendo utilizada em atividades agrícolas, na navegação e para bombeamento de água. Atualmente, contribui principalmente para o abastecimento global de energia elétrica, sendo uma alternativa para os sistemas tradicionais de geração que, em geral, são mais poluentes.

O mercado energético junto com os leilões de energia fizeram com que o preço das renováveis fosse tão competitivo quanto das outras fontes. O resultado foi uma rápida expansão da indústria eólica ao redor do mundo nos últimos anos. Em 2017, atingiu-se a marca de 540 GW de capacidade instalada de usinas eólicas em operação (Tabela 1). É estimado que até 2022, mundialmente tenha-se 840 GW de capacidade instalada pela fonte, representando um crescimento de 56 % em relação a 2017 (GWEC, 2017).

Tabela 1. Capacidade instalada de energia eólica em 2017 (GWEC, 2017).

Nova Capacidade Instalada em 2017			Capacidade Instalada Acumulada Até 2017		
País	MW	%	País	MW	%
China	19.660	37	China	188.392	35
EUA	7.017	13	EUA	89.077	17
Alemanha	6.581	13	Alemanha	56.132	10
Reino Unido	4.270	8	Índia	32.848	6
Índia	4.148	8	Espanha	23.170	4
Brasil	2.022	4	Reino Unido	18.872	4
França	1.694	3	França	13.759	3
Turquia	766	1	Brasil	12.763	2
África do Sul	618	1	Canadá	12.239	2
Finlândia	535	1	Itália	9.479	2
Outros	5.182	10	Outros	82.391	15
Total Top 10	47.311	90	Total Top 10	456.731	85
Total Mundo	52.493	100	Total Mundo	539.122	100

Nas próximas seções, são abordadas questões técnicas sobre os aerogeradores, a geração de energia elétrica e a aquisição de dados dos parques eólicos.

2.1.1. Energia Eólica no Brasil

O Brasil é um país favorecido pela disponibilidade de diversos tipos de recursos renováveis em sua extensão com potencial de exploração energética. A demanda nacional por energia é suprida majoritariamente por empreendimentos hidrelétricos, que atualmente compõem 60% da capacidade instalada do país (EPE, 2017). No entanto, esta fração vem reduzindo-se, uma vez que outros modais surgem para diversificar o suprimento de energia na matriz nacional (Figura 1).

Segundo LIMA et al. (2018), diversos impactos estão associados à implementação de uma usina hidrelétrica, podendo-se citar as mudanças no percurso natural do corpo d'água, o deslocamento de populações ribeirinhas, perda de biodiversidade e emissões de GEEs. Assim, a busca por outras alternativas de geração de energia tornam-se justificáveis.

A necessidade por fontes de energia sustentáveis, a insegurança energética nacional e a instabilidade do mercado de petróleo fizeram com que novas fontes alternativas ganhassem destaque nas últimas décadas, principalmente a eólica. No Brasil, a rápida expansão do setor também esteve associada aos incentivos feitos pelo governo, como por exemplo, o Programa de Incentivo às Fontes Alternativas de Energia (PROINFA), criado em 2002.

Em 2018, a eólica era responsável por 8% da capacidade instalada do Sistema Interligado Nacional (SIN), e espera-se que esta contribuição aumente nos próximos anos. No mesmo ano, o Brasil atingiu a capacidade instalada de 14 GW de geração eólica, com 530 usinas operando no país, ocupando o oitavo lugar no ranking mundial de produção de energia eólica (ABEEÓLICA, 2018).

O crescimento acelerado da eólica no Brasil pode ser associado à qualidade dos ventos encontrados no país. A média do fator de capacidade das usinas brasileiras é superior à média mundial, sendo que no Nordeste, o fator atinge valores acima de 60% (ABEEÓLICA, 2018). Assim, a instalação de empreendimentos eólicos no Brasil é atrativa e, portanto, espera-se que o crescimento do modal continue nos próximos anos.

O Plano Decenal de Expansão de Energia (EPE, 2017) estima que, em 2027, o Brasil contará com o suprimento de 27 GW pela fonte eólica, um acréscimo de 116% em relação à 2017, contribuindo para a redução das emissões de gases do efeito estufa oriundos de geração de energia elétrica.

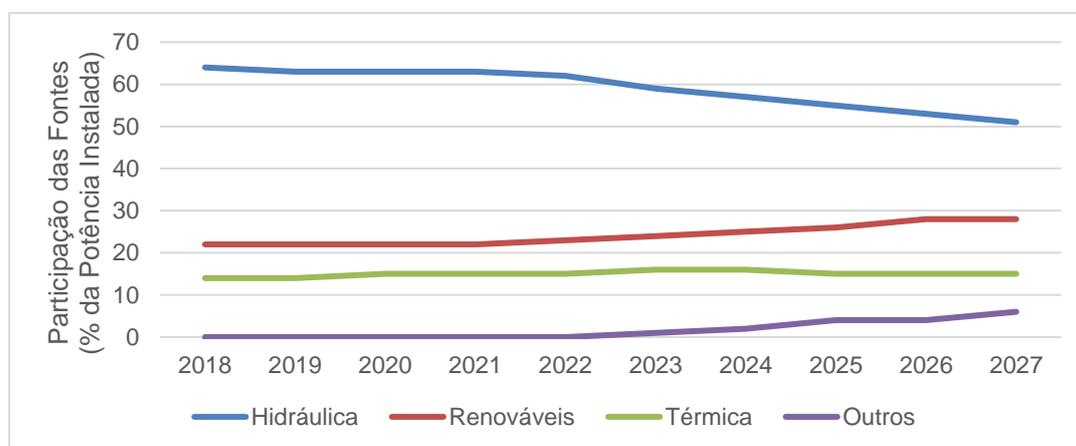


Figura 1. Participação das fontes de energia no SIN ao longo de 2018 até 2027. O grupo *Renováveis* é composto por pequenas centrais hidrelétricas, biomassa, solar e eólica.

Fonte: EPE, 2017.

2.1.2. Aerogeradores

A transformação dos ventos em eletricidade é feita por turbinas eólicas, também chamadas de aerogeradores. São compostas por três elementos principais: a torre, a nacelle e o rotor com as pás.

A torre é responsável por sustentar a nacelle e o rotor, mantendo-os a uma altura adequada que permita uma maior captação dos ventos. Sabe-se que a rugosidade exerce uma força de atrito sob o escoamento do ar, que é mais intenso em altitudes próximas à superfície, assim, a elevação do rotor potencializa geração de energia elétrica (SALINO, 2011).

A nacelle é o componente que abriga diversos outros componentes, como o gerador elétrico, o multiplicador de velocidade, o sistema de freios e o sistema de motores. É posicionada sobre a torre e sustenta o eixo do rotor.

A captação de energia se dá pela dinâmica entre o vento e as pás, que fazem o rotor girar, transferindo energia mecânica para o gerador, que é convertida em elétrica. Posteriormente, a energia vai a um transformador, para que a voltagem da eletricidade se torne adequada às linhas de transmissão, chegando até a subestação da usina.

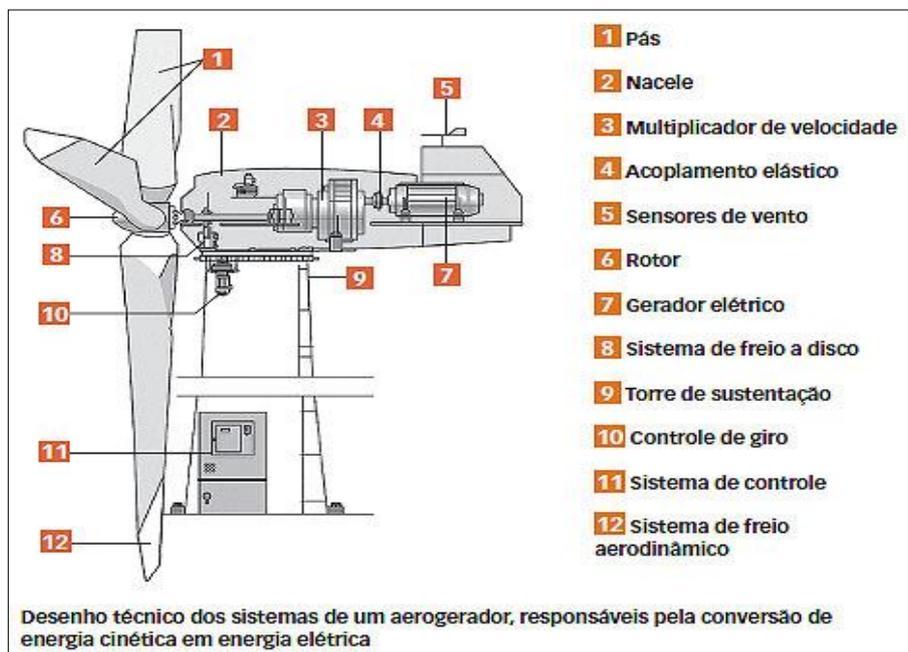


Figura 2. Componentes de um aerogerador

Fonte: Infraestrutura Urbana, 2011

Diversos modelos de turbinas foram desenvolvidos, buscando-se obter a captação mais eficiente da energia dos ventos. A turbina de eixo horizontal com três pás é a mais difundida no mercado, devido à viabilidade econômica e à performance do modelo. Menos pás conferem um pior aproveitamento do recurso eólico, enquanto, mais pás elevam o custo do projeto de forma que o ganho de performance não é suficiente para torná-lo viável (CASTRO, 2008).

As turbinas de três pás apresentam uma rotação mais suave que as turbinas com uma ou duas pás, e, portanto, não demandam componentes adicionais, como juntas e amortecedores de movimento no eixo. Além de baratear o projeto, esta configuração reduz o ruído emitido durante a operação das turbinas (MELO, 2012).



Figura 3. Aerogerador de três pás

Fonte: Portal Energia, 2015

Os aerogeradores modernos têm capacidade para operar com ventos de 3 m/s a 25 m/s e são flexíveis para serem instalados em diferentes condições climáticas, desde desertos até zonas árticas (MELO, 2012). A capacidade instalada de um aerogerador em um parque eólico *onshore* varia entre 2,0 a 4,0 GW.

2.1.3. Rendimento do Aerogerador

A energia disponível nos ventos está associada à sua cinética, ou seja, à sua massa e à sua velocidade de escoamento. Assim, a potência disponível no deslocamento de massa de ar em um fluxo pode ser descrita pela Equação 1.

$$P_v = \frac{1}{2} \rho A v_1^2 \quad (1)$$

onde:

P_v = potência média do vento em Watts (W);

ρ = densidade do ar;

A = área de varredura do rotor (m²);

v_1 = velocidade média do vento (m/s).

Porém, a potência aproveitada pela turbina (P_t) é menor que P_v , devido às perdas associadas ao processo de captação e conversão energética. Esquemmatizando um fluxo unidirecional através de uma turbina (Figura 4), pode-se descrever a P_t pela Equação 2.

$$P_t = \frac{1}{2} \rho A (v_1^2 - v_2^2) \quad (2)$$

onde:

v_2 = velocidade média do vento a jusante (m/s).

A quantidade que pode ser convertida em potência mecânica pela turbina é definida pelo coeficiente de potência (c_p). A relação indica qual é o rendimento das turbinas ao converter a energia dos ventos.

$$c_p = \frac{P_t}{P_v} = \frac{\text{Potência extraída pela turbina}}{\text{Potência disponível no vento}} \quad (3)$$

Existe um limite teórico para o c_p , que indica a quantidade de potência máxima que um rotor ideal consegue converter em mecânica. Este valor é denominado *Limite de Betz*, e equivale a 0,593, ou seja, teoricamente, apenas 59,3% da potência disponível no fluxo de ar que passa pelas turbinas pode ser aproveitada. Em geral, as turbinas atingem coeficientes de 0,35 a 0,45 (AMARAL, 2011).

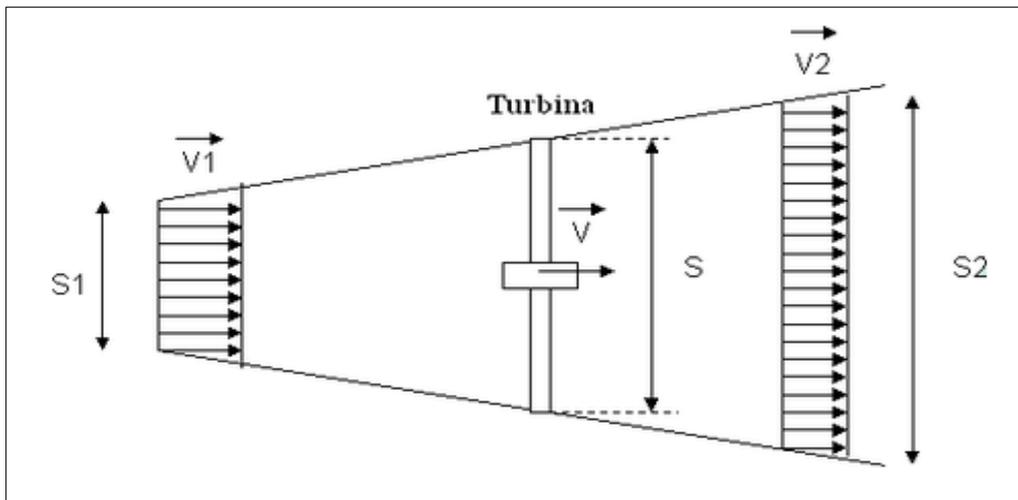


Figura 4. Fluxo unidirecional do vento em um aerogerador

Fonte: Micro Eólica, 2018.

2.1.4. Curva de Potência

A potência de uma turbina varia de acordo com a velocidade do vento incidente, assim, é possível definir uma curva característica do aerogerador, conhecida como curva de potência (Figura 5). Pode-se realizar previsões de desempenho da turbina utilizando apenas dados de vento, sem considerar aspectos técnicos de seus componentes, simplificando o comportamento da geração dos aerogeradores ou do parque eólico.

O gráfico da curva de potência apresenta informações importantes sobre a turbina, como a velocidade mínima, a velocidade nominal e a velocidade de corte (AMARAL, 2011).

- **Velocidade Mínima:** Velocidade mínima do vento em que a turbina começa a gerar energia, ou seja, as pás começam a movimentar-se, superando as forças de atrito nos componentes.
- **Velocidade Nominal:** Velocidade em que a turbina atinge sua potência máxima.
- **Velocidade Máxima:** Velocidade em que a turbina sai de operação devido à alta velocidade dos ventos, o que pode danificar o equipamento.

Os dados de vento utilizados na construção da curva de potência são obtidos por anemômetros que serão detalhados na próxima seção.

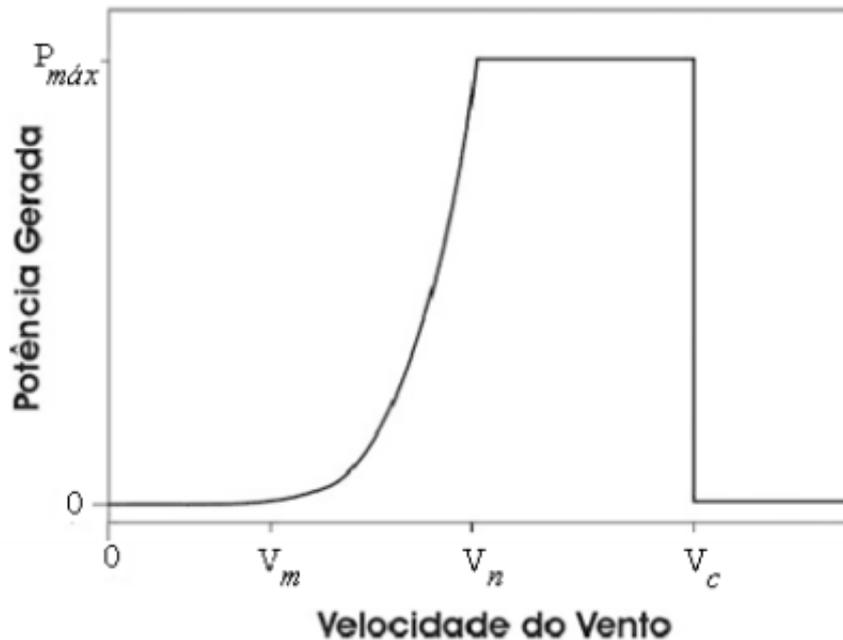


Figura 5. Exemplo de curva de potência de um aerogerador. V_m é a velocidade mínima, V_n é a velocidade nominal e V_c é a velocidade de máxima.

Fonte: AMARAL, 2011

2.1.5. Anemômetros

A medição da velocidade do vento é uma etapa fundamental para diversas análises do potencial eólico de uma região, já que se pode inferir diversos aspectos operacionais do parque por meio de dados do vento. Para este procedimento, são utilizados os anemômetros, sensores de alta precisão que medem a velocidade e direção do deslocamento de massas de ar no ponto em que são instalados.

Há diversas categorias de anemômetros disponíveis no mercado, cada um com características técnicas distintas. Os mais utilizados são os anemômetros de copo e os ultrassônicos.

Os anemômetros de copo (Figura 6) possuem pás côncavas acopladas a um rotor. Quando giram em torno de seu eixo, criam mudanças eletromagnéticas que são captadas por um sensor, que as traduz como sinais elétricos. Tem como vantagem sua robustez, simplicidade e custo competitivo comparado com os outros modelos.



Figura 6. Anemômetro de copo

Fonte: Messtechnik, 2018

Os anemômetros ultrassônicos (Figura 7) conseguem medir a velocidade do vento em três dimensões com uma qualidade melhor que os outros sensores. O equipamento emite e capta sinais ultrassônicos, que sofrem variações em função do estado do vento que passa pelo sensor. Apesar de ter uma alta acurácia, estes anemômetros possuem um preço mais elevado e consomem mais energia para o seu funcionamento.

Os sensores são instalados em torres anemométricas para realizar a medição de dados em diferentes alturas. É comum a instalação de um anemômetro na altura dos rotores dos aerogeradores, para que os dados possam ser mais coerentes com o comportamento dos ventos nas turbinas eólicas.



Figura 7. Anemômetro ultrassônico

Fonte: Tecnal, 2018

De modo a garantir uma padronização e qualidade nas medições de vento por parte dos agentes eólicos, foi elaborada uma norma internacional, a IEC 61400-12 (IEC, 2005), que especifica o correto procedimento de instalação dos sensores nas torres anemométricas, e define critérios sobre a quantidade e qualidade das medições de dados de vento.

2.1.6. Torres anemométricas

A análise do recurso eólico é essencial para a etapa de prospecção de um projeto de parque eólico, pois, é necessária a estimativa da produção anual de energia da usina para se calcular a receita esperada do projeto. Para isto, instala-se uma torre de medição equipada com anemômetros e outros sensores para realizar a leitura de dados meteorológicos do local, como a velocidade e direção do vento, temperatura, pressão, umidade e densidade do ar. Após a medição, estas variáveis são armazenadas em um equipamento chamado *data logger*, localizado na própria torre, que é responsável por gravar dados de sensores conectados a ele através do tempo.

As instalações, chamadas de torres anemométricas, medem a velocidade do vento em diferentes alturas para possibilitar uma análise detalhada do perfil vertical do recurso eólico. Idealmente, deve-se posicionar um dos anemômetros na altura do eixo das turbinas eólicas a serem instaladas, para que haja uma medição mais precisa do comportamento do vento nas turbinas.

2.2. Métricas de erros

É necessário descrever algumas métricas de erros previamente à contextualização dos modelos de previsão do setor eólico, para que se possa estabelecer uma sensibilidade quanto ao desempenho dos mesmos. As métricas de erros são os indicadores de performance das metodologias, e de quanto elas geram previsões assertivas.

Até o presente momento, não há uma padronização de avaliação de desempenho de modelos de geração eólica. No entanto, encontram-se na literatura especializada algumas métricas de erros com mais frequência (KARINIOTAKIS et al., 2005). Pode-se citar: *mean absolute percent error* (MAPE), *normalized mean absolute percent error* (NMAPE) e *root mean square error* (RMSE).

As métricas possuem características distintas, portanto, é indicado realizar análises com diferentes métricas para se ter uma visão abrangente da performance do modelo.

O MAPE é o erro definido pela média das diferenças absolutas entre os valores previsto e verificado, dividida pelo valor verificado (Equação 4).

$$MAPE = \frac{1}{n P_{verificado}} \sum_{i=1}^n |P_{previsto} - P_{verificado}| \times 100 \quad (4)$$

onde:

n é a quantidade de intervalos de tempo analisados;

$P_{prevista}$ é a potência prevista pelo modelo;

$P_{verificada}$ é a potência medida.

Na avaliação de modelos de previsão de geração eólica, o NMAPE é encontrado frequentemente na literatura por ser uma métrica de fácil compreensão e representativa. É definida como a média dos erros absolutos entre os valores gerados e os medidos,

normalizada pela potência nominal da usina eólica, apresentando unidade percentual (Equação 5).

$$NMAPE = \frac{1}{n P_{nominal}} \sum_{i=1}^n |P_{previsto} - P_{verificado}| \times 100 \quad (5)$$

onde:

$P_{nominal}$ é a potência nominal da usina em questão;

O RMSE é a raiz quadrada do erro médio entre os valores calculados e medidos (Equação 6), e possui mesma unidade que os dados avaliados, no presente trabalho, quilowatt. É uma métrica que discrimina dispersões maiores, uma vez que as diferenças são elevadas ao quadrado antes de calcular-se a média dos erros.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n |P_{verificada} - P_{prevista}|^2}{n}} \quad (6)$$

2.3. Modelos de Previsão

Diversos modelos de previsão de geração de energia vêm sendo usados desde meados do século XX. Mais especificamente, os modelos para energia eólica vêm sendo desenvolvidos desde 1980. Cada metodologia adotada possui vantagens e desvantagens que devem ser analisadas para que o modelo se compatibilize com as necessidades dos modeladores. A escala de tempo da previsão, a capacidade computacional requerida e a disponibilidade de dados são variáveis que indicam o modelo mais adequado para determinado parque eólico.

Os modelos que primeiramente realizam a previsão do vento para obter a previsão de geração de energia através de uma curva de potência representativa são chamados de modelos indiretos. Já os que realizam as previsões de geração em uma única etapa, são chamados de modelos diretos (VARGAS, 2015).

Atualmente, não há uma padronização na classificação temporal das previsões eólicas na literatura especializada, sendo que é possível encontrar diferentes agrupamentos para o mesmo horizonte de previsão. A Global Wind Energy Council (GWEC) faz a classificação de acordo com a Tabela 2. Segundo VARGAS (2015), previsões de 1 até 72 h são feitas para programação de operação de curto prazo e despacho. Já as previsões de 3 até 7 dias são utilizadas para o planejamento da manutenção dos parques eólicos e programação da manutenção da rede e das operações de armazenamento de energia.

A segunda classificação diz respeito à metodologia empregada no modelo. Os modelos podem ser generalizados em três grupos: modelos físicos, modelos estatísticos e modelos baseados em Inteligência Artificial (IA). Os modelos que apresentam uma combinação de dois ou mais métodos são chamados de modelos híbridos, que buscam garantir uma ferramenta mais estável e eficiente.

Tabela 2. Classificação da escala temporal de previsões eólicas (WORLD ENERGY COUNCIL, 2016)

Escala	Horizonte
Curtíssimo Prazo	Alguns minutos até uma hora à frente
Curto Prazo	Uma hora até diversas horas à frente
Médio Prazo	Diversas horas até uma semana à frente
Longo Prazo	Uma semana até anos à frente

Os modelos físicos são aqueles que se baseiam nas análises realizadas por métodos numéricos para prever o comportamento climático de uma região (VARGAS, 2015). Estes métodos utilizam fórmulas físicas para descrever as interações e dinâmicas entre os componentes meteorológicos, e são capazes de realizar previsões climáticas a partir das condições atuais do meio modelado (verificadas por meio de medições). Após a obtenção de previsões climáticas, é calculada a previsão de geração de energia através de uma curva de potência representativa do parque eólico ou por algum método de regressão (FREITAS et al., 2016).

Uma das dificuldades em executar os métodos numéricos é a demanda por capacidade computacional, já que os modelos precisam calcular diversas equações para simular as dinâmicas meteorológicas, o que torna o tempo de execução longo.

Como alternativa, pode-se encontrar previsões de vento de modelos já rodados disponíveis publicamente, geradas por instituições com infraestrutura computacional suficiente para a rápida execução destes métodos. Um exemplo são as previsões do modelo *Global Forecast System* (GFS), mantido pelo *National Centers for Environmental Prediction* (NCEP), capaz de realizar previsões para até 10 dias com uma resolução espacial de 13 km e temporal de uma hora, e para até 16 dias com uma resolução de 34 km e três horas de intervalo de tempo (NCEP, 2016). A saída do GFS é disponibilizada quatro vezes ao dia em seu servidor, sendo aberta publicamente para aquisição¹. Por tratar-se de um modelo que abrange o globo inteiro, a resolução espacial é ampla. Assim, suas previsões não são exatas para locais pontuais (como a posição de uma torre de medição de vento). Portanto, são necessários ajustes dos NWP, para que as previsões sejam transpostas de uma escala global para regional, fazendo com que os dados tenham mais coerência com as análises preditivas de usinas eólicas. O método de *downscaling* reduz a grade espacial do modelo numérico e utiliza dados de modelos de escalas menores como entrada das condições de fronteira do modelo, simulando novamente as interações meteorológicas em uma área de interesse menor, porém, com um maior detalhamento.

FREITAS et al. (2017) utilizaram previsões do GFS como entrada de um modelo de *downscaling* para gerar previsões de geração de energia para 72 horas à frente. Utilizando filtros para ajustes de dados e uma regressão cúbica para a conversão de vento em potência, os autores obtiveram RMSE equivalente a 100,52 kW para as previsões de uma turbina de 500 kW de potência nominal.

Os modelos estatísticos baseiam-se essencialmente em aplicações de métodos estatísticos sobre dados históricos da usina, como vento, temperatura, potência, entre outros. Segundo a pesquisa bibliográfica de VARGAS, o modelo ARIMA é o mais utilizado tradicionalmente. O método consiste em processos autorregressivos integrados à média móvel para realizar previsões de vento e geração de energia de um parque. Estes modelos captam a correlação de variáveis em função de uma série temporal, extrapolando estas tendências de crescimento ou decaimento para o futuro. Uma variação deste modelo é o ARIMAX, que adiciona variáveis exógenas ao cálculo das previsões. CARMELO et al. (2017) utilizaram o método incluindo precipitação, temperatura e pressão como entradas exógenas do modelo para prever-se as médias mensais de velocidade do vento em Fortaleza, Natal e Parnaíba. Os autores obtiveram MAPE variando de 8 a 10% em seus resultados. Segundo VARGAS (2015), outros

¹ <http://nomads.ncep.noaa.gov/>

métodos estatísticos encontrados na literatura incluem AR, Filtro de Kalman, ARFIMA VAR, entre outros.

Mais recentemente, os modelos baseados em IA vêm sendo adotados para a resolução de problemas preditivos. A IA é o ramo da engenharia computacional que busca criar máquinas ou *softwares* inteligentes, capazes de reproduzir a capacidade racional do ser humano na resolução de problemas. Os avanços computacionais ocorridos nas últimas décadas permitiram a realização de cálculos mais complexos em um menor intervalo de tempo. Assim, novos métodos baseados em IA têm sido propostos para a obtenção das previsões de vento e de geração eólica, como, por exemplo, as Redes Neurais Artificiais (RNA), Lógica Fuzzy, ANIFS, ELMAN, entre outros (VARGAS, 2015).

DE GIORGI et al. (2011) estudaram diferentes modelos para realizar a previsão de potência de um parque eólico italiano em terreno complexo, com condições meteorológicas instáveis. Os métodos testados foram um estatístico (ARMA) e diversos baseados em IA (ANFIS, MLFF, ELMAN e MLP). A melhor configuração do ARMA obteve NMAPE de 23,67 % para previsões de 24 horas. Já os modelos de IA tiveram desempenho semelhantes entre si, variando o NMAPE de 14 a 16 % para o mesmo horizonte de previsão.

KARINIOTAKIS et al. (2004) avaliaram a variação do desempenho de 11 modelos de previsão em função da complexidade do terreno de seis locais diferentes da Europa. Os modelos foram superiores em locais de menor complexidade, obtendo um NMAPE médio de aproximadamente 10 % para 12 horas de previsão, enquanto terrenos complexos obtiveram valores de até 21 %. Os autores concluíram que a performance das previsões foi otimizada utilizando diferentes modelos de previsão em conjunto, e que não há uma metodologia que seja melhor em todas as situações, sendo necessária a análise de diversas metodologias para cada caso modelado.

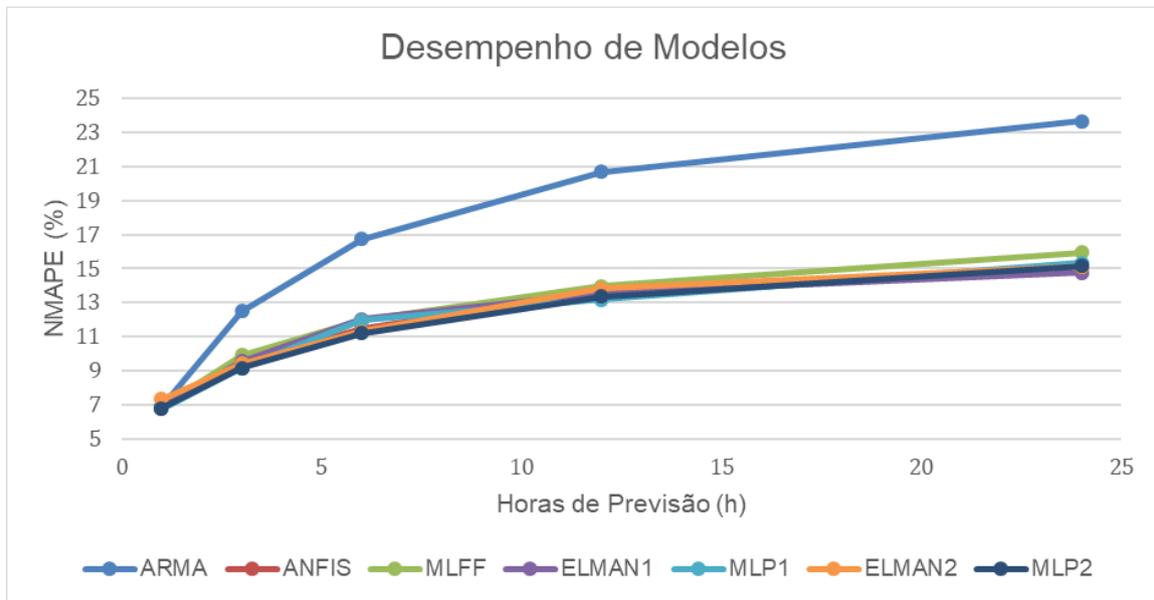


Figura 8. NMAPE dos modelos analisados por De Giorgi, Ficarella e Tarantino (2010) para previsões de geração para até 24 horas.

Fonte: Elaboração própria com dados de De Giorgi, Ficarella e Tarantino (2010).

Muitos estudos encontrados na literatura avaliam o desempenho dos modelos analisados comparando-os com modelos de persistência. O modelo assume que o comportamento da velocidade e direção do vento e a energia gerada permanecem de modo análogo ao que se verificou no instante anterior à previsão (SANTOS, 2009), conforme a Equação 7.

$$P_t = P_{t-j} \quad (7)$$

onde:

t é o intervalo de tempo horário que varia entre $[0, \infty)$;

j é o horizonte de previsão.

O modelo de persistência é comumente encontrado na literatura especializada como modelo de referência. Assim, é utilizado para mensurar a performance dos modelos propostos, indicando se houve melhora sobre a persistência ou não.

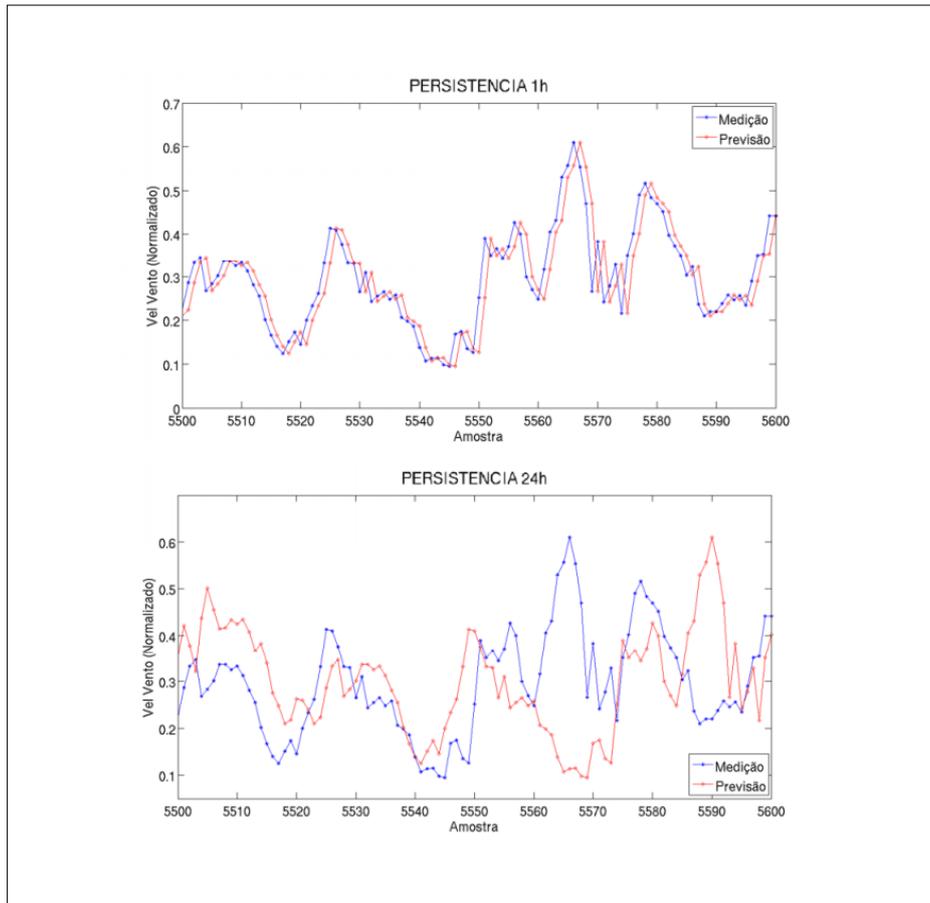


Figura 9. Representação de um modelo de persistência para velocidade de vento. Em cima, a persistência de um modelo para uma hora à frente, embaixo, para 24 horas à frente. O dado medido (azul) gera os dados previstos (vermelho), transpondo os intervalos da amostra.

Fonte: BEZERRA et al., 2018.

2.4. Redes Neurais Artificiais

As redes neurais artificiais (RNA) são modelos computacionais baseados no sistema nervoso central dos animais, emulando a dinâmica das células nervosas biológicas em uma rede neural. O método consiste no aprendizado de máquina, que é o processo em que um programa é capaz de aprender a resolver determinada tarefa

sem ser explicitamente programado para isso. Assim, um modelo de RNA consegue reconhecer padrões e tomar decisões a partir de observações de dados, experiências ou instruções que são inseridas como entrada do modelo.

Uma rede pode ser entendida como um modelo que recebe valores de entrada, e retorna valores de saída. As entradas passam pela rede sendo alteradas pela memória da RNA, que nada mais é do que um conjunto de pesos que ponderam estes valores que percorrem a rede. Biologicamente, os animais aprendem a realizar tarefas a partir de um treinamento que é dado a eles, ou seja, é preciso mostrar padrões e submetê-los a experiências para que eles consigam reproduzir a tarefa desejada. Analogamente, para uma RNA, o mesmo deve ser feito, fornecendo dados que representem suficientemente os padrões necessários para o cumprimento da tarefa.

Uma RNA é composta por unidades de processamento simples chamadas de neurônios. Elas são dispostas em uma ou mais camadas interligadas por conexões denominadas sinapses. O modelo é baseado em métodos estatísticos não lineares, portanto, conseguem resolver problemas mais complexos, sendo amplamente utilizado para resolução de problemas de classificação e regressão (VELLASCO, 2007).

Os neurônios de uma RNA são baseados no modelo de McCulloch e Pitts (HAYKIN, 1994), ilustrado na Figura 10. As entradas recebidas pelos neurônios podem ser descritas como um vetor x de dimensão igual à quantidade de parâmetros de entradas e y sendo a saída do neurônio, seguindo para a próxima unidade da rede.

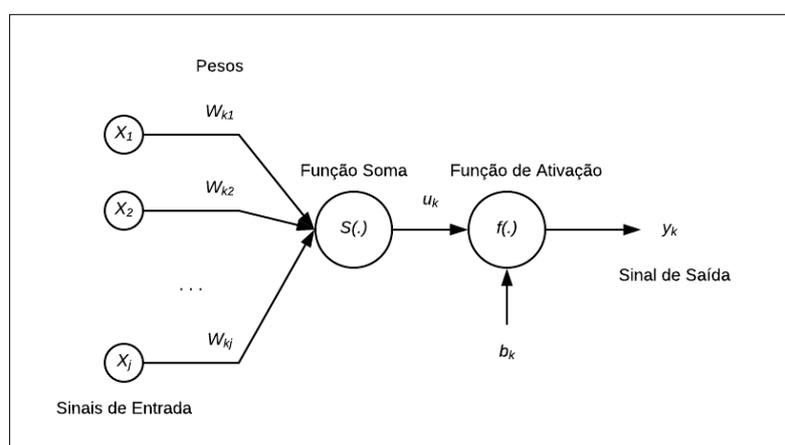


Figura 10. Representação esquemática do k-ésimo neurônio de uma RNA.

Fonte: Elaboração própria baseado em VELLASCO, 2007

Os W 's correspondem aos pesos que ponderam as entradas do neurônio, e são considerados como a memória da rede, já que são os parâmetros que são ajustados quando a rede é treinada (VELLASCO, 2007). u_k é a soma ponderada das entradas pelos pesos W . $f(.)$ é a função de ativação, a unidade não linear do neurônio. A função recebe u_k como entrada e retorna um valor correspondente por meio de uma função pré-determinada. Por fim, b_k é o termo polarizador que indica o quanto a função de ativação está acima do eixo, corrigindo qualquer viés existente na ativação. De forma geral, a saída de um neurônio pode ser representada pelas Equações 8 e 9.

$$y = f(u) + b \quad (8)$$

$$u = \sum x w \quad (9)$$

Diversas funções podem ser utilizadas como função de ativação. Pode-se citar a sigmoide, tangente hiperbólica e ReLU, que é similar a uma função linear para $x \geq 0$ e igual a zero para $x < 0$. Com elas, a RNA é capaz de conferir relações não lineares entre as variáveis dependentes e independentes, descrevendo relações mais complexas que os métodos lineares. A adoção de determinada função não é trivial, sendo responsabilidade do modelador escolher uma função que seja adequada ao problema a ser resolvido (VELLASCO, 2007).

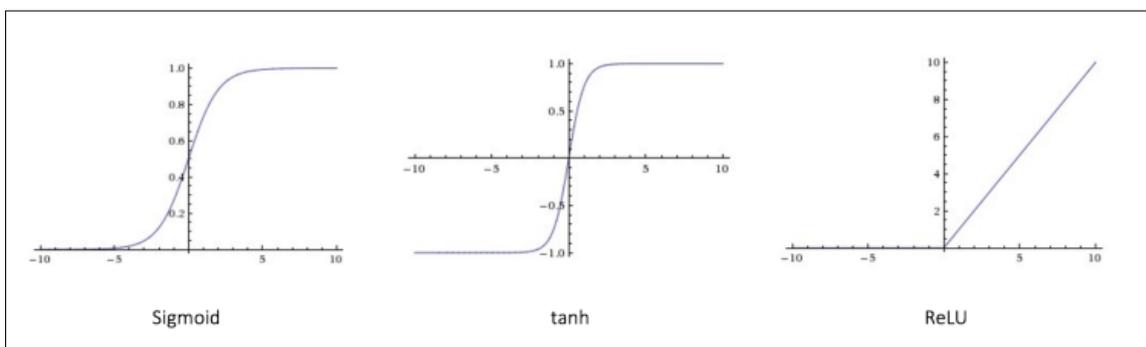


Figura 11. Funções de Ativação

Fonte: Data Science Blog, 2016

Uma RNA do tipo *perceptron* consiste em apenas um neurônio, sendo dificilmente empregada para resolver tarefas complexas, devido à simplicidade de sua estrutura. Quando a rede possui múltiplas camadas com um ou vários neurônios, ela é chamada de *Multilayer Perceptron* (MLP), e apresenta uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (VELLASCO, 2007).

A camada de entrada é onde os dados vão ser recebidos pela rede. A camada de saída é onde é dada a resposta da rede após o processamento dos sinais de entrada. Por fim, as camadas ocultas são as que estão entre a entrada e saída, e são responsáveis exclusivamente pelo processamento dos sinais que passam entre elas. Uma representação esquemática de uma rede MLP é ilustrada da Figura 12.

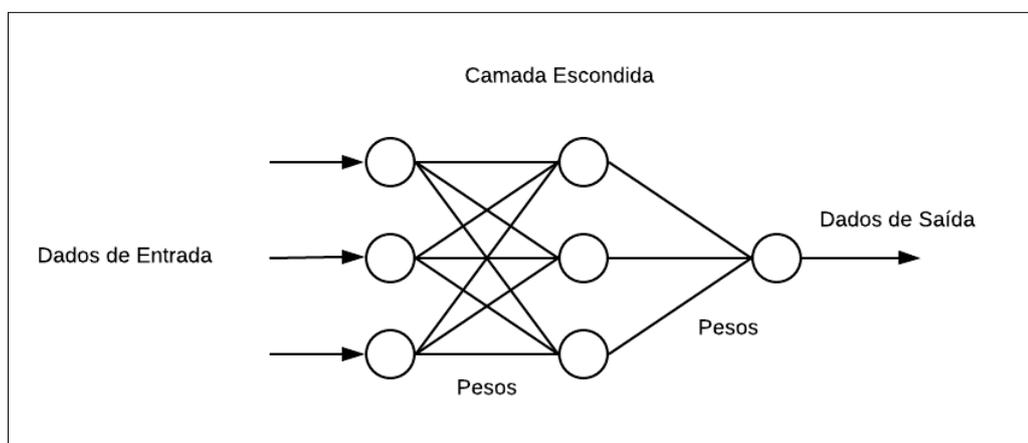


Figura 12. Estrutura de uma rede neural artificial. Cada círculo representa uma unidade de processamento.

Fonte: Elaboração própria baseado em VELLASCO, 2007.

Uma RNA é desenvolvida por meio do aprendizado que se dá a ela. Assim, é necessário fornecer uma base de dados suficiente e representativa para que a rede possa ser treinada a resolver determinada tarefa. Assim, os pesos mencionados anteriormente são gradativamente alterados, absorvendo os padrões que são ensinados à rede. O processo de treinamento pode ser classificado como supervisionado ou não supervisionado.

No treinamento supervisionado, um conjunto de resultados esperados na saída da rede é fornecido (RUELA, 2012). O método baseia-se na saída calculada da rede, comparando este valor com a saída alvo fornecida. A diferença entre os valores

configura um erro que é utilizado para realizar os ajustes dos pesos da rede. Espera-se que a cada iteração de treinamento, a rede seja aperfeiçoada, minimizando a diferença entre valores calculados e fornecidos.

No treinamento não supervisionado, não são fornecidos alvos de saída para a rede. Assim, deve ser dada uma medida independente da tarefa que deve ser aprendida, e os parâmetros são ajustados em função a essa medida (VELLASCO, 2007).

Em uma rede MLP, o treinamento é supervisionado, e o algoritmo de treinamento mais utilizado é o *backpropagation* (VELLASCO, 2007). Ele consiste em calcular o erro na saída da rede e retropropagá-lo pelas camadas, alterando os pesos mencionados anteriormente para minimizar o erro na próxima saída. O algoritmo baseia-se no método do gradiente descendente, o qual cria gradientes de atualização dos pesos com base no gradiente do erro calculado.

A aprendizagem por *backpropagation* pode ser resumida em duas etapas:

- Propagação: fase de propagação dos sinais de entrada da rede, processando-os através dos neurônios e gerando uma resposta na saída da rede. Nesta fase, os pesos são constantes, e apenas ponderam os sinais nas entradas dos neurônios.
- Retropropagação: etapa em que ocorre o ajuste dos pesos em função à diferença da saída calculada e do valor alvo fornecido. A resposta ao erro ocorre em sentido contrário ao que ocorre na etapa de propagação. Assim, as camadas mais próximas à saída possuem seus pesos atualizados primeiro.

O erro na saída da rede pode ser definido como na Equação 10 (ADEBAYO et al., 2018). K é referente aos neurônios da camada de saída, y é a saída calculada pela rede na etapa de propagação e t é a saída alvo fornecida.

$$E = \frac{1}{2} \sum_{k \in K} e_k^2 \quad (10)$$

$$e_k = (y_k - t_k) \quad (11)$$

Portanto, o ajuste dos pesos W é dado pelo gradiente $\frac{\partial E}{\partial W}$. Como o erro só é dado pela saída da RNA, o algoritmo de *backpropagation* trata o ajuste dos erros na camada de saída e na camada oculta (VELLASCO, 2007).

Para a camada de saída, sendo j referente aos neurônios que enviam sinais à camada de saída, o gradiente é dado pela Equação 12.

$$\frac{\partial E}{\partial W_{jk}} = \frac{\partial}{\partial W_{jk}} \frac{1}{2} \sum_{k \in K} (y_k - t_k)^2 \quad (12)$$

$$\frac{\partial E}{\partial W_{jk}} = (y_k - t_k) \frac{\partial}{\partial W_{jk}} y_k \quad (13)$$

Como y_k é a saída da função de ativação dos neurônios da camada de saída, a Equação 13 pode ser reescrita como:

$$\frac{\partial E}{\partial W_{jk}} = e_k \frac{\partial}{\partial W_{jk}} f(u_k) \quad (14)$$

$$\frac{\partial E}{\partial W_{jk}} = e_k f(u_k) f'(u_k) \frac{\partial}{\partial W_{jk}} u_k \quad (15)$$

$$\frac{\partial E}{\partial W_{jk}} = e_k y_k f'(u_k) y_j \quad (16)$$

Assim, pode-se resumir o gradiente pela Equação 17.

$$\frac{\partial E}{\partial W_{jk}} = y_j \delta_k \quad (17)$$

$$\delta_k = e_k y_k f'(u_k) \quad (18)$$

O parâmetro δ é uma virtualização do erro calculado na saída retropropagado pela RNA.

Para a camada oculta, o gradiente é dado pela Equação 19. i refere-se à entrada do neurônio, e j, à saída.

$$\frac{\partial E}{\partial W_{ij}} = \frac{\partial}{\partial W_{ij}} \frac{1}{2} \sum_{k \in K} (y_k - t_k)^2 \quad (19)$$

$$\frac{\partial E}{\partial W_{ij}} = \sum_{k \in K} (e_k) f(u_k) f'(u_k) \frac{\partial}{\partial W_{ij}} u_k \quad (20)$$

Isolando a derivada parcial, encontra-se:

$$\frac{\partial u_k}{\partial W_{ij}} = \frac{\partial u_k}{\partial y_j} \frac{\partial y_j}{\partial W_{ij}} \quad (21)$$

$$\frac{\partial u_k}{\partial y_j} = W_{jk} \quad (22)$$

$$\frac{\partial y_j}{\partial W_{ij}} = f(u_j) f'(u_j) y_j \quad (23)$$

Portanto, organizando as derivadas parciais com a Equação 20, encontra-se:

$$\frac{\partial E}{\partial W_{ij}} = y_i y_j f'(u_j) \sum_{k \in K} \delta_k W_{jk} \quad (24)$$

Assim, como para a camada oculta, pode-se resumir a Equação 24 na seguinte forma:

$$\frac{\partial E}{\partial W_{ij}} = y_i \delta_j \quad (25)$$

$$\delta_j = y_j f'(u_j) \sum_{k \in K} \delta_k W_{jk} \quad (26)$$

Pode-se definir uma regra para as camadas ocultas, seguindo a Equação 27. Sendo λ o índice da camada da RNA. Percebe-se o sentido da retropropagação na dependência de uma camada com a seguinte.

$$\delta_\lambda = y_\lambda f'(u_\lambda) \sum W_{\lambda+1} \delta_{\lambda+1} \quad (27)$$

Portanto, a atualização dos pesos W segue a forma da Equação 28.

$$\Delta W = -\eta \delta_\lambda y_{\lambda-1} \quad (28)$$

Sendo ΔW a atualização dos pesos e η a taxa de aprendizado da RNA.

Como o termo polarizador não se relaciona com as entradas e saídas dos neurônios por meio de produto ou divisão, ele é atualizado seguindo a Equação 29.

$$\Delta b = -\eta\delta_\lambda \quad (29)$$

A taxa de aprendizado de uma RNA define o quão rápido a atualização dos pesos acontece. Quanto menor o η , mais devagar o erro converge em zero, assim como o contrário também ocorre.

O ajuste dos pesos pode ser descrito pela Equação 30, sendo d estado atual dos pesos e $d + 1$ o estado ajustado.

$$W_{d+1} = W_d + \Delta W \quad (30)$$

$$b_{d+1} = b_d + \Delta b \quad (31)$$

Após uma iteração da retropropagação, um novo conjunto de dados de treinamento é utilizado, e o processo se repete, até que um erro suficientemente pequeno é atingido ou os dados de treinamento acabarem.

Após a aprendizagem da RNA com os pesos devidamente ajustados, ela é capaz de realizar previsões baseadas em novos dados de entrada, reproduzindo padrões que foram fornecidos no período de treinamento.

3. Metodologia

Visto a relevância dos modelos de previsão de geração eólica, o presente trabalho buscou desenvolver e avaliar um modelo baseado no método das RNAs e compará-lo com um modelo de persistência e um modelo físico. Assim, a metodologia desenvolvida pode ser dividida em cinco etapas:

- Aquisição de dados
- Modelo A - Redes Neurais Artificiais
- Modelo B - Físico
- Modelo C - Persistência
- Avaliação de modelos

A Figura 13 ilustra a metodologia aplicada no presente trabalho.

Para o desenvolvimento dos modelos e das ferramentas de aquisição de dados, foi utilizada a linguagem de programação Python. Os módulos utilizados ao longo da metodologia estão descritos na Tabela 3.

Tabela 3. Módulos do Python utilizados por etapas da metodologia

Módulo	Etapa	Função
Pandas	Todas	Manipulação e processamento de dados
Numpy	Todas	Módulo de computação científica
Scipy	Modelo B	Regressão Linear
Sklearn	Modelo A	Modelo de RNA
Pygrib	Aquisição de dados	Leitura de arquivos do modelo GFS
Ftplib	Aquisição de dados	Acesso ao servidor do NCEP
Apscheduler	Aquisição de dados	Execução dos códigos em horários programados
Sqlalchemy	Todas	Acesso ao banco de dados para leitura e gravação

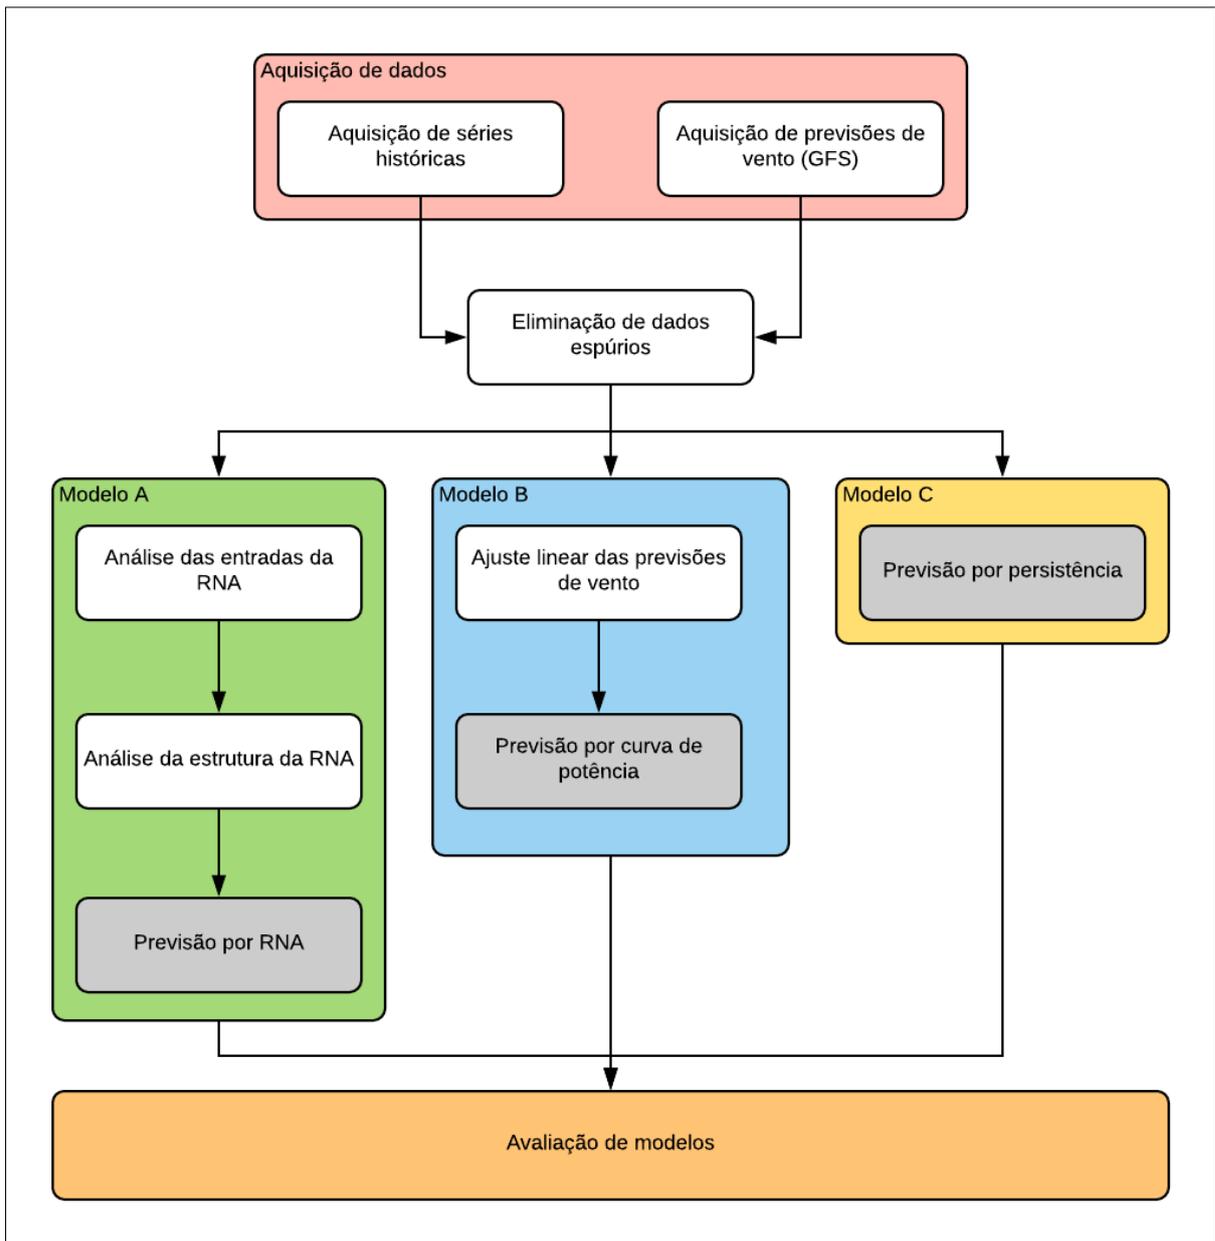


Figura 13. Etapas da metodologia desenvolvida

Fonte: Elaboração própria

3.1. Aquisição de dados

A primeira etapa da metodologia foi obter os dados que foram utilizados como entrada nos modelos desenvolvidos. Para isso, foi escolhida uma usina eólica como

fornecedora de dados, para que fosse possível uma avaliação do desempenho das previsões geradas em um caso real.

O parque eólico analisado está localizado no Rio Grande do Norte (RN, Brasil), e é denominado no presente trabalho como *Parque Modelo*. A usina tem capacidade nominal de 27,3 MW, e situa-se em um terreno com pouca declividade.

Os dados obtidos foram séries temporais de velocidade de vento (m/s), geração de energia (kWh) e temperatura (°C), no período de aproximadamente seis meses. As séries possuem intervalo de tempo de dez minutos, no entanto, foram promediadas em uma hora para ficarem na mesma resolução que as previsões de geração (Equação 32).

$$u_{\text{horário}} = \sum_{i=1}^6 \frac{u_i}{6} \quad (32)$$

onde:

u representa os parâmetros de entrada com intervalo de dez minutos.

Para a aquisição de dados, foi desenvolvido um bloco de código na linguagem de programação Python que se comunica com o banco de dados do *Parque Modelo*. A função desenvolvida era responsável por executar consultas no banco e obter as séries históricas de vento e temperatura da torre anemométrica da usina, e de produção de energia, lidos pelos medidores de energia da subestação.

Paralelamente, outro código foi utilizado para obter dados do modelo GFS, para serem utilizados no Modelo B. O código acessava o servidor FTP do NCEP diariamente, e lia os dados de previsão de vento para até 16 dias à frente. Em seguida, eram armazenados em um banco de dados MySQL.

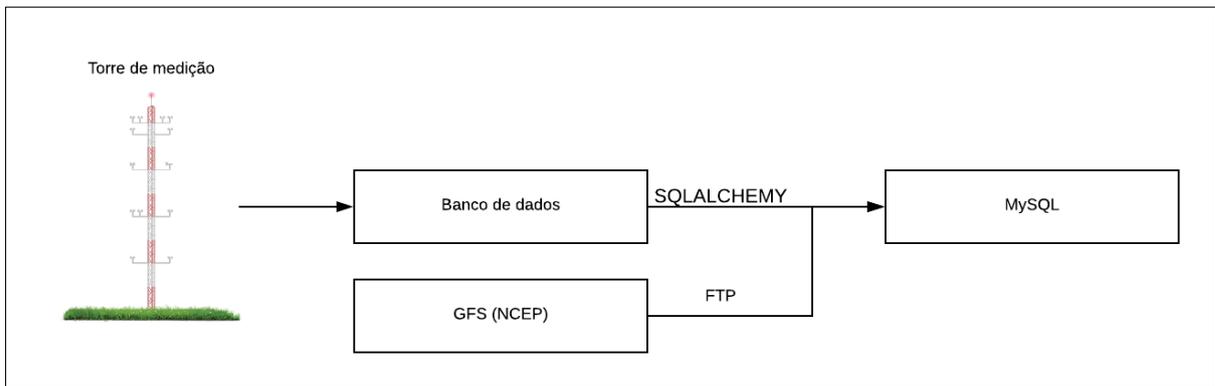


Figura 14. Aquisição de dados utilizados nos modelos

Fonte: Elaboração própria

3.2. Divisão de Dados

Uma vez que se deseja analisar o desempenho dos modelos desenvolvidos no presente trabalho, é necessário que haja uma separação lógica das séries temporais utilizadas na metodologia.

Os dados armazenados formam séries temporais de 4500 intervalos de tempo, de dez minutos cada, tendo uma leitura de aproximadamente um mês. As séries foram divididas da seguinte forma:

- Os primeiros 3000 intervalos de tempo foram utilizados para o treinamento do Modelo A;
- Os 500 intervalos seguintes foram utilizados para realizar as análises estruturais do Modelo A, portanto, alguns parâmetros ainda são ajustados;
- Os últimos 1000 intervalos são utilizados para análises de desempenho dos Modelos A, B e C.

3.3. Modelo A - RNA

Para o desenvolvimento do Modelo A, diversas análises foram feitas visando identificar a melhor configuração da RNA para o caso proposto. Para isso, as análises foram desenvolvidas em códigos na linguagem Python.

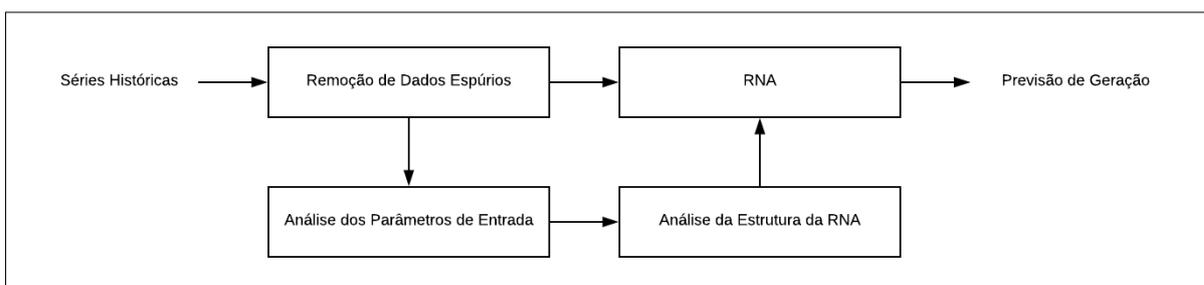


Figura 15. Processos da metodologia do Modelo A

Fonte: Elaboração própria

3.3.1. Dados de entrada

As questões levantadas no desenvolvimento de arquitetura da rede neural estão relacionadas a quais parâmetros deveriam ser utilizados como dados de entrada (velocidade de vento, temperatura e/ou pressão). Portanto, diferentes configurações foram testadas para avaliar quais os parâmetros mais relevantes para o modelo. Para esta metodologia, apenas dados históricos de medição foram utilizados como entrada, ou seja, dados do modelo GFS não foram utilizados nesta etapa.

A RNA utilizada para este teste possui duas camadas escondidas com 20 neurônios. A Tabela 4 descreve os arranjos de entrada testados. Não houve premissa para a escolha da estrutura utilizada, visto que esta foi analisada no teste posterior, explicado na seção seguinte.

Tabela 4. Arranjos de parâmetros de entrada para a RNA

Modelo	Parâmetros
Modelo A-1.1	Geração
Modelo A-1.2	Vento
Modelo A-1.3	Geração e temperatura
Modelo A-1.4	Vento e temperatura
Modelo A-1.5	Geração e vento
Modelo A-1.6	Geração, vento e temperatura

Foi feita uma análise de auto correlação dos dados de geração para identificar os períodos que possuem relação mais forte com o horizonte da previsão gerada. A auto correlação mede a dependência de um processo em um instante (t) e um instante posterior ($t + j$).

Os dados utilizados eram referentes aos cinco últimos registros de cada parâmetro (H-1, ..., H-5) e os cinco períodos de maior correlação com o horizonte da previsão. Quando os instantes se repetiam, apenas uma ocorrência era computada, evitando dados de entrada redundantes. Os dados também foram normalizados, transformando a distribuição de dados em uma distribuição de média zero e desvio padrão unitário, e isso faz com que o treinamento da rede seja mais eficiente, já que variáveis com diferentes escalas são computadas em conjunto.

Foram feitas previsões para um dia à frente (D+1), comparando-as com os valores medidos de geração. O processo é recursivo e varre todas as séries temporais de dados disponíveis, obtendo o erro médio para todo o período analisado. O processo está ilustrado na Figura 16.

Foram utilizados 3000 intervalos de tempo para o treinamento da rede e 500 intervalos para análise de performance.

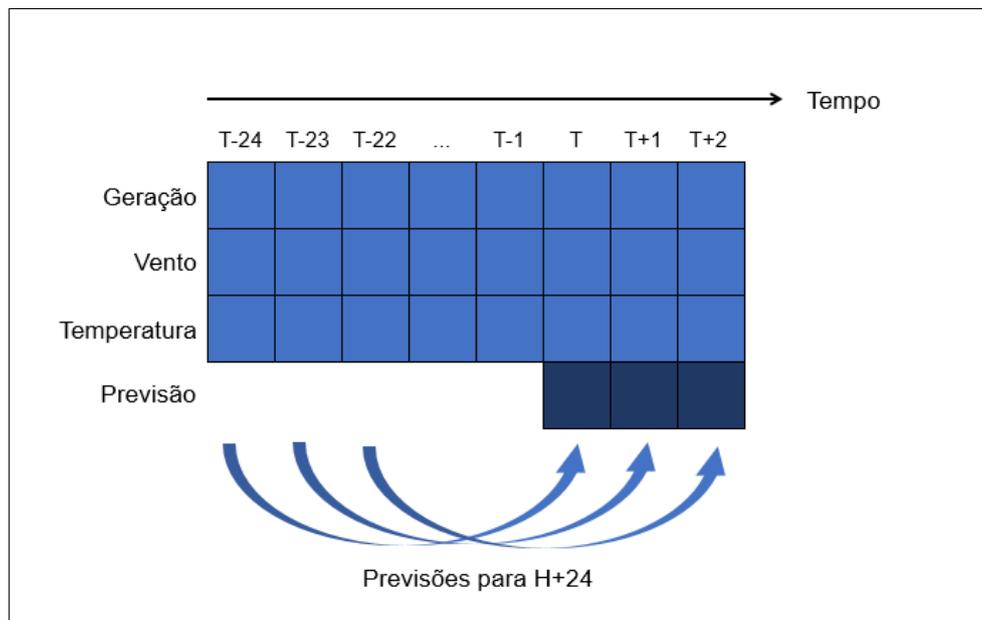


Figura 16. Código varrendo os históricos de dados, gerando uma série de previsão de geração H+24

Fonte: Elaboração própria

3.3.2. Arquitetura da RNA

A arquitetura da rede também deve ser analisada, uma vez que não há como definir a opção ótima sem realizar análises de desempenho de cada configuração. Utilizando o melhor arranjo obtido na análise anterior, diferentes estruturas foram testadas. A Tabela 5 apresenta as análises feitas.

Tabela 5. Estruturas testadas da RNA (número de neurônios)

Modelo	Camada 1	Camada 2	Camada 3
Modelo A - 2.1	10	0	0
Modelo A - 2.2	20	0	0
Modelo A - 2.3	30	0	0
Modelo A - 2.4	10	10	0
Modelo A - 2.5	20	10	0
Modelo A - 2.6	30	10	0
Modelo A - 2.7	20	20	0
Modelo A - 2.8	30	20	0
Modelo A - 2.9	10	10	10
Modelo A - 2.10	20	20	20
Modelo A - 2.11	30	30	30

Foram utilizados 3000 intervalos de tempo para o treinamento da rede e 500 intervalos para a validação e análise de performance. Os resultados analisados foram as previsões geradas para um dia a frente (D+1), assim como a análise anterior.

3.3.3. Avaliação do desempenho do modelo

Após as análises da configuração da rede neural, uma avaliação da atuação do modelo foi feita comparando as previsões de geração eólica geradas com dados verificados de energia. Para isso, rodou-se o código do modelo iterativamente, e, para cada intervalo da série temporal de teste, realizaram-se previsões de geração eólica para um horizonte de até cinco dias a frente (D+5), a cada hora. Foram utilizados outros 1000 intervalos de tempo para a avaliação do modelo.

3.4. Modelo B - Físico

O Modelo B é baseado em métodos físicos, utilizando resultados do modelo GFS como entrada para o cálculo da previsão de geração eólica. A metodologia desta etapa consiste em um ajuste linear das previsões de vento, construção da curva de potência de referência da usina e conversão de previsão de vento em previsão de geração de energia.

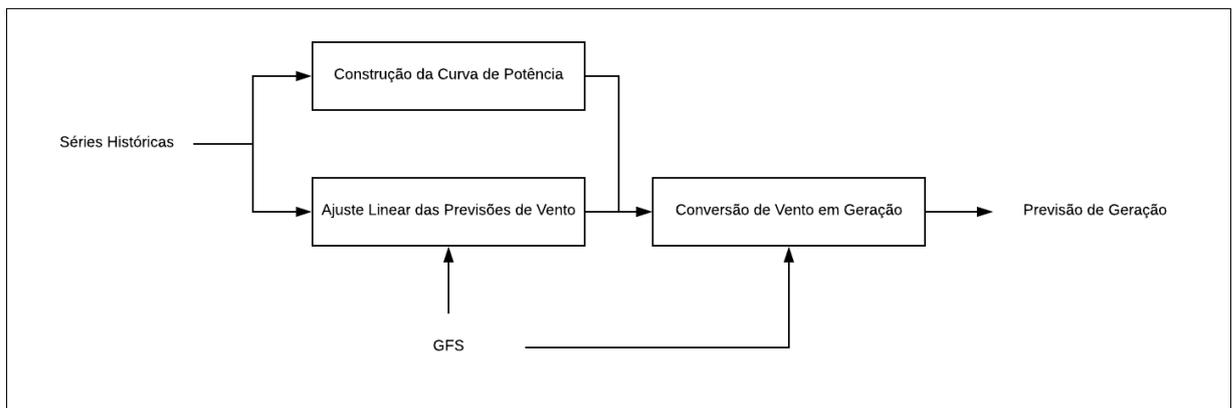


Figura 17. Processos da metodologia do Modelo B

Fonte: Elaboração própria

3.4.1. Ajuste linear

O modelo GFS é um modelo numérico que utiliza equações físicas para prever o comportamento dos sistemas climatológicos do planeta. Foram utilizadas as previsões de velocidade de vento do modelo como entrada do Modelo B.

Devido ao tamanho da grade do GFS, muitas vezes é necessário realizar um ajuste nos dados de previsão de vento, para torná-los mais representativos para a usina em questão.

Foi escolhido utilizar o método da regressão linear simples para fazer um ajuste das previsões de vento, por meio de um viés linear entre as previsões históricas e dados medidos de velocidade de vento. A regressão linear é uma ferramenta estatística que

descreve a relação de uma variável dependente y e uma variável independente x , ajustando uma reta com coeficiente de interceptação α e um coeficiente de declividade β .

$$y = \alpha + \beta x \quad (33)$$

Utiliza-se o Método dos Mínimos Quadrados (MMQ) para ajustar a linha entre uma dispersão de dados (Equações 34 a 36), buscando a minimização da soma dos quadrados dos erros (BUSSAB, 2014).

$$SQ(\alpha, \beta) = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2 \quad (34)$$

$$\frac{\partial SQ}{\partial \alpha} = 0 \quad (35)$$

$$\frac{\partial SQ}{\partial \beta} = 0 \quad (36)$$

3.4.2. Curva de Potência

Para a definição da curva de potência de referência do Parque Modelo, foram utilizadas as séries históricas de vento e geração obtidos pelos códigos desenvolvidos. Foi feita uma remoção dos dados inválidos utilizando os seguintes critérios:

- Registros de velocidade de vento negativos ou acima de 30 m/s;
- Dados nulos;
- Dados dispersos;
- Dados quando turbina está fora de operação normal;

Após a remoção, os dados foram agrupados em intervalos de 0,5 m/s, e a média da potência de cada grupo foi calculada, representando a curva de potência da usina (Equação 37).

$$P_v = \frac{1}{n} \sum_{i=1}^n P_i \quad (37)$$

onde:

P_v é a média das potências de cada agrupamento de ventos;

n é o número de amostras em cada agrupamento.

3.4.3. Conversão em Geração

Com os dados ajustados de previsão de vento e a curva de potência representativa da usina, pode-se obter a previsão de geração da usina. Como a curva de potência está descrita de forma discreta, é necessário realizar a interpolação dos dois pontos vizinhos à velocidade de vento prevista.

Assim, foram calculadas as previsões de geração para o período de teste (1000 intervalos de tempo), as previsões possuem um horizonte temporal de até cinco dias à frente (D+5) e estão na base diária.

3.5. Modelo C - Persistência

O Modelo C é baseado na persistência da geração de energia do Parque Modelo. Considerou-se que o último dado medido de geração permanecesse estático no futuro, gerando previsões similares ao apresentado na Figura 9.

Assim como no Modelo B, o código do Modelo C foi rodado iterativamente entre o período de teste, tendo 1000 intervalos de tempo para avaliação do desempenho do modelo.

3.6. Avaliação entre Modelos

Após o desenvolvimento dos códigos de cada modelo, foi necessário avaliar o desempenho de cada um, utilizando as métricas mencionadas anteriormente. Para o presente trabalho, foi avaliada o NMAPE, utilizando como fator de normalização a potência nominal da usina (27,3 MW), e o RSME.

Todos os modelos utilizaram os mesmos 1000 intervalos de tempo para realizar as previsões, para que a integridade da comparação fosse mantida, atribuindo os erros somente às metodologias, e não aos dados utilizados.

Também foi analisada a diferença da performance das previsões utilizando o Modelo A em relação aos outros modelos, conforme a Equação 38. Utilizando as análises de performance na base diária, foi calculada a relação do erro do Modelo A pelo erro de B e C.

$$perf_{AB,AC} = \left(\frac{NMAPE_A}{NMAPE_{B,C}} - 1 \right) 100 \quad (38)$$

Assim, pode-se mensurar a diferença de performance de um modelo de RNA, em relação a um modelo físico e de persistência.

4. Resultados

Neste capítulo são apresentados os resultados obtidos para as análises estruturais referente ao Modelo A, assim como o desempenho que cada modelo teve com o Parque Modelo. Por fim, uma análise comparativa é feita entre os três modelos testados.

4.1. Modelo A

A função de autocorrelação obtida (Figura 18) mostra que os dados mais recentes de geração possuem maior correlação que os dados mais antigos. No entanto, é possível identificar que a cada 24 horas, há uma maior correlação do que com os intervalos vizinhos. Isso ocorre devido à permanência do comportamento do Parque Modelo no período analisado. Portanto, é esperado que o modelo de permanência apresente melhor desempenho para intervalos de 24 horas para o parque em questão.

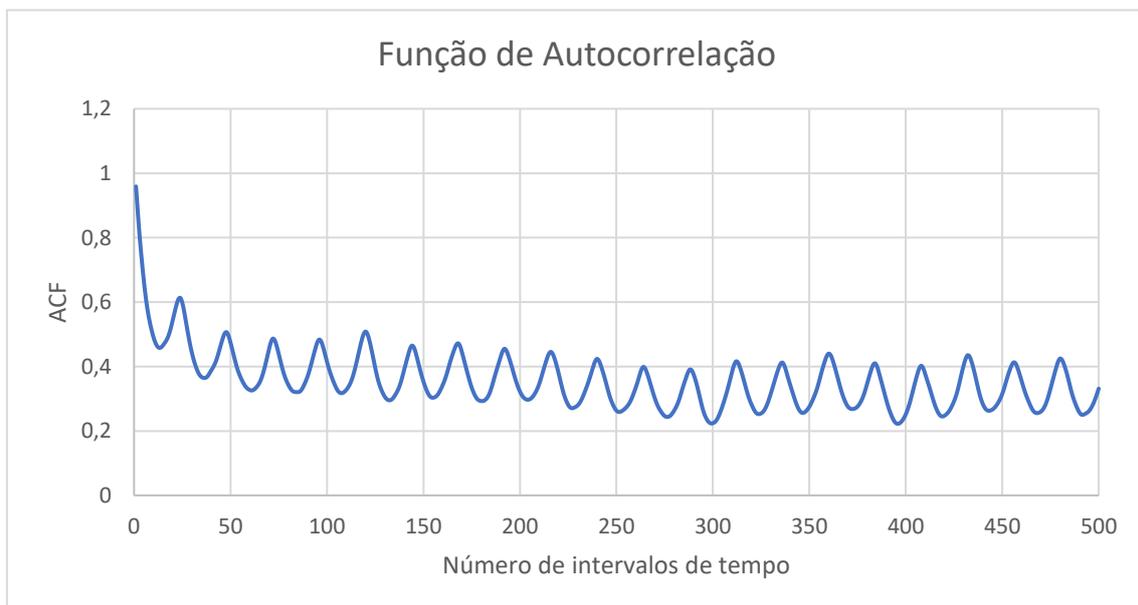


Figura 18. Função de autocorrelação de geração de energia do Parque Modelo. Cada intervalo corresponde a 1 hora. O eixo y corresponde à correlação que a geração no instante t tem com a geração no instante t mais o número de intervalos.

Fonte: Elaboração própria

Foi realizada a escolha dos parâmetros de entrada da RNA alterando arranjos de dados e analisando os erros dos modelos auxiliares para previsões de H+24 (Tabela 6). Foi constatado que o Modelo A-1.5 apresentou menores erros, indicando que a melhor escolha para os parâmetros de entrada seria de vento e geração para este caso. Portanto, a temperatura não foi utilizada no Modelo A.

Tabela 6. Análise da performance de diferentes dados de entrada na RNA

Modelo	NMAPE (%)	RMSE (kWh)
Modelo A-1.1	10,44	4529,09
Modelo A-1.2	10,29	4481,57
Modelo A-1.3	10,38	4612,45
Modelo A-1.4	10,50	4601,26
Modelo A-1.5	9,68	4212,94
Modelo A-1.6	10,32	4523,58

Após a seleção dos dados de entrada, foi feita a análise da estrutura da rede neural, testando diversos arranjos livremente escolhidos. Os resultados obtidos estão representados na Tabela 7, o melhor modelo foi o 2.7, ou seja, a rede de duas camadas com 20 neurônios em cada. A estrutura da rede escolhida como definitiva está ilustrada na Figura 19.

Tabela 7. Análise de estruturas da RNA

Modelo	NMAPE (%)	RMSE (kWh)
Modelo A - 2.1	10,30	4370,82
Modelo A - 2.2	10,08	4301,98
Modelo A - 2.3	10,37	4415,91
Modelo A - 2.4	10,39	4445,22
Modelo A - 2.5	10,48	4522,42
Modelo A - 2.6	10,58	4464,92
Modelo A - 2.7	9,68	4212,94
Modelo A - 2.8	10,24	4397,55
Modelo A - 2.9	10,15	4543,60
Modelo A - 2.10	10,13	4441,59
Modelo A - 2.11	10,26	4490,74

Observou-se que o desempenho do modelo não está relacionado com complexidade da estrutura da rede, porém, todos os arranjos testados nas duas análises apresentaram resultados similares, variando o NMAPE de 9,68 a 10,58 %, e RMSE de 4212 a 4613 kW.

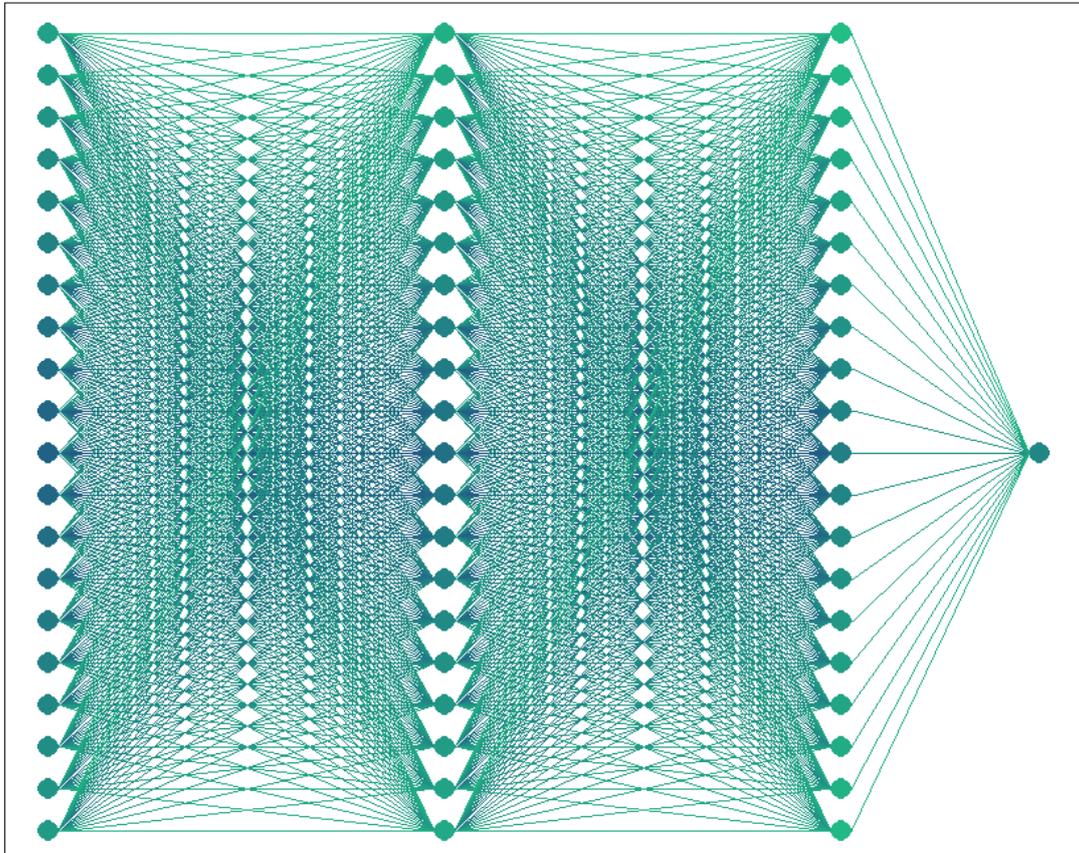


Figura 19. Estrutura da rede escolhida. A primeira coluna corresponde aos dados de entrada (os cinco dados mais recentes e de maior correlação de vento e geração); a segunda e a terceira são as camadas ocultas; e a última é a camada de saída (previsão de geração).

Fonte: Elaboração própria.

Em seguida, foi realizada a análise hora a hora dos erros para o Modelo A, desejando-se observar uma relação entre o desempenho e horizonte de previsão. Os resultados obtidos estão ilustrados nas Figura 20 e 21.

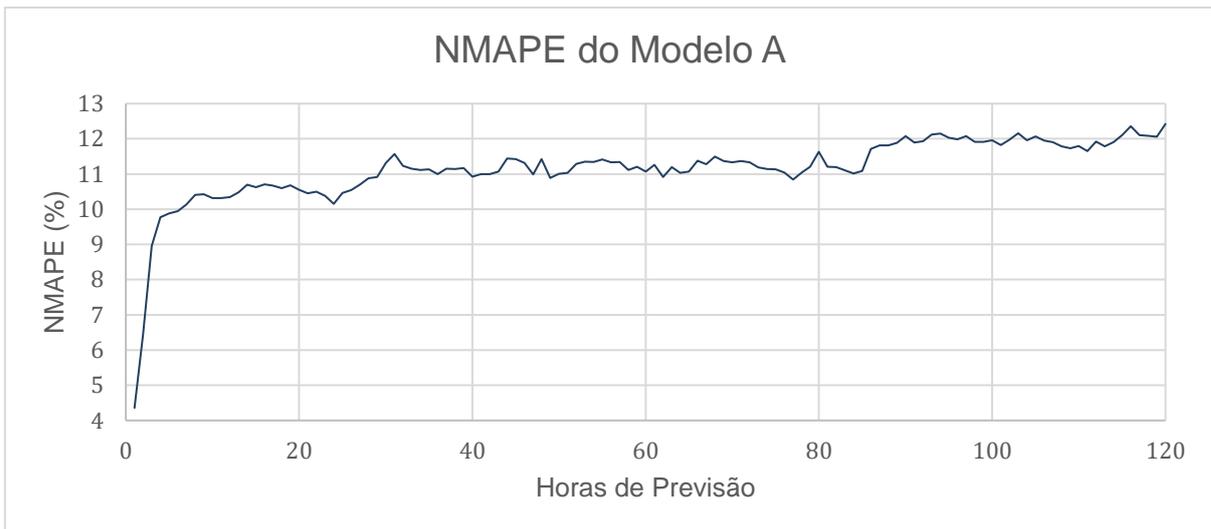


Figura 20. NMAPE do Modelo A por horas de previsão

Fonte: Elaboração própria

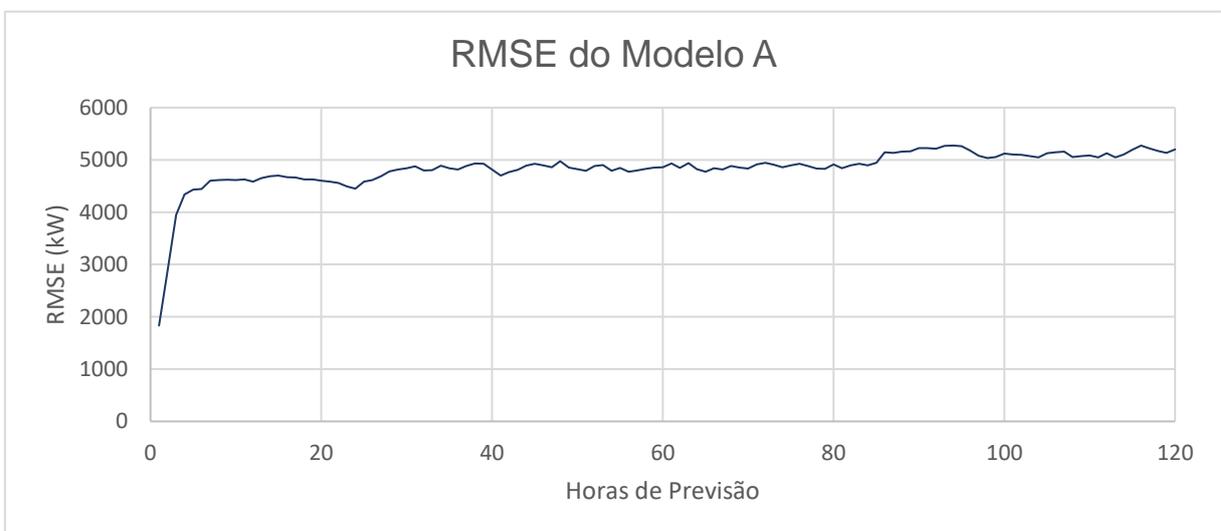


Figura 21. RMSE do Modelo A por horas de previsão

Fonte: Elaboração própria

Segundo os gráficos, é possível inferir que os resultados são coerentes com a função de autocorrelação obtida. Para previsões de horizontes mais curtos, o desempenho é melhor, sendo o erro obtido de 4,36% para uma hora à frente. Também é possível verificar uma variação crescente nos erros conforme as horas de previsão aumentam.

4.2. Modelo B

A regressão linear para o Modelo B foi feita para ajustar os ventos do modelo GFS ao vento verificado pela torre anemométrica presente no Parque Modelo. A relação está ilustrada na Figura 22.

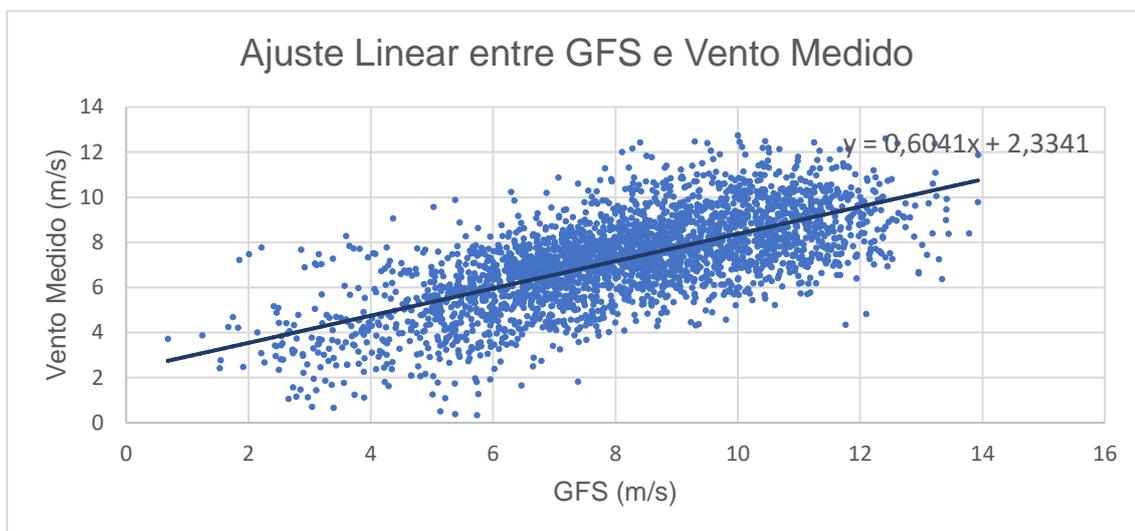


Figura 22. Dispersão de dados de vento previsto (GFS) e verificado

Fonte: Elaboração própria

Percebe-se que há grande dispersão entre os dados, podendo ser atribuído a diversas causas, como: simplicidade da formulação da relação, erros do modelo numérico e erros de medição do anemômetro.

Após a obtenção da relação linear entre o vento modelado e o verificado, foi feito o ajuste dos ventos previstos dos dados de teste.

Para a construção da curva de potência de referência do Parque Modelo, foi realizada uma filtragem dos dados de potência e vento da usina, conforme especificado anteriormente. Esta etapa é necessária, devido às indevidas inferências causadas pela má qualidade de alguns dados. O efeito da filtragem no cálculo da curva de potência pode ser confirmado pelas Figura 23 e 24.

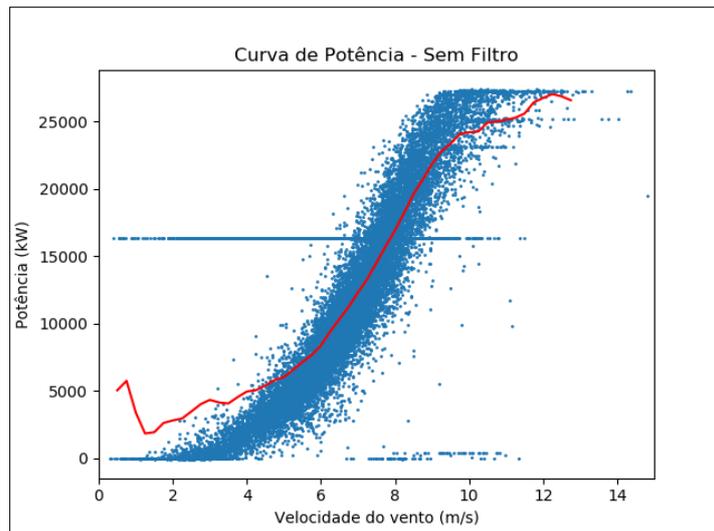


Figura 23. Curva de potência representativa do Parque Modelo (vermelho) antes da aplicação do filtro

Fonte: Elaboração Própria

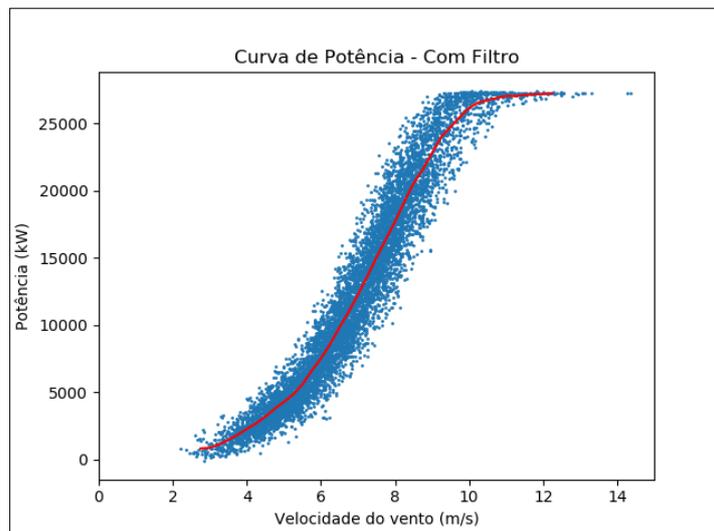


Figura 24. Curva de potência representativa do Parque Modelo (vermelho) após a filtragem de dados espúrios

Fonte: Elaboração própria

Com a curva de potência representativa e os dados de previsão de vento ajustados, foi feita a conversão de velocidade de vento em potência, gerando-se as previsões do Modelo B.

4.3. Comparação entre modelos

A média diária dos erros de cada modelo foi calculada a fim de avaliar a performance de cada um para o parque em questão. Foi utilizado o mesmo período de teste para todos os modelos. Os resultados estão ilustrados na Figura 25.

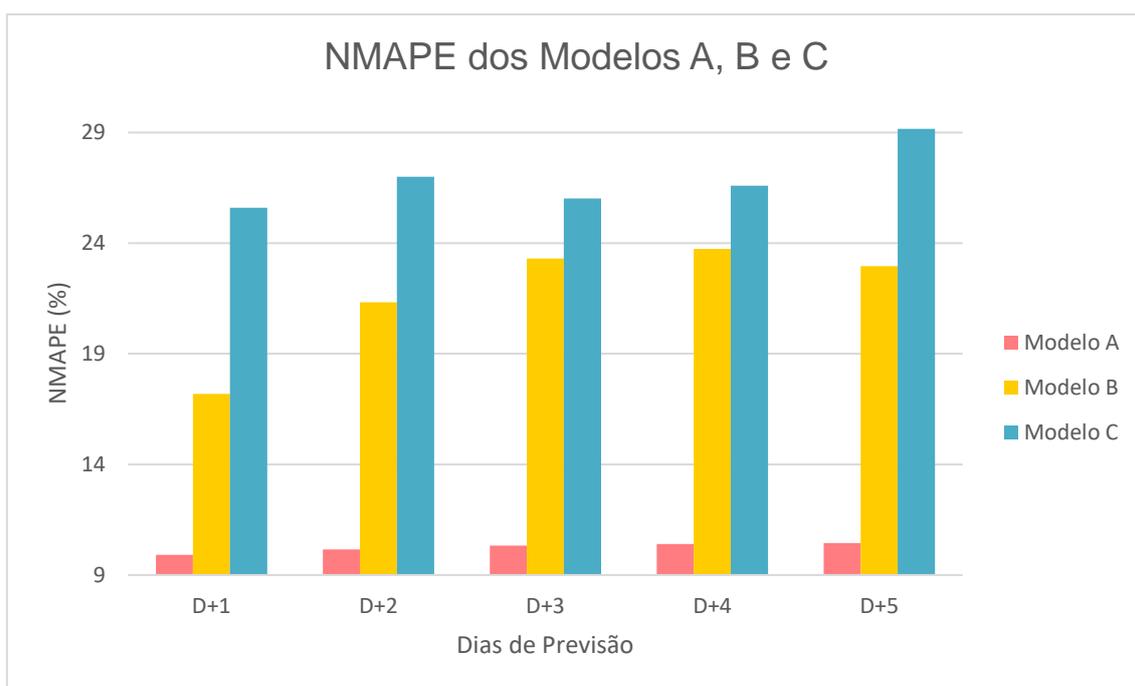


Figura 25. NMAPE média diário dos Modelos A, B e C por dias de previsão

Fonte: Elaboração própria

Pode-se observar que o Modelo A apresentou melhores resultados que os outros dois, e foi o modelo que resultou em menor variação do erro médio diário entre o horizonte analisado, sendo o NMAPE para o primeiro dia igual a 9,90% e para o quinto, 10,45%.

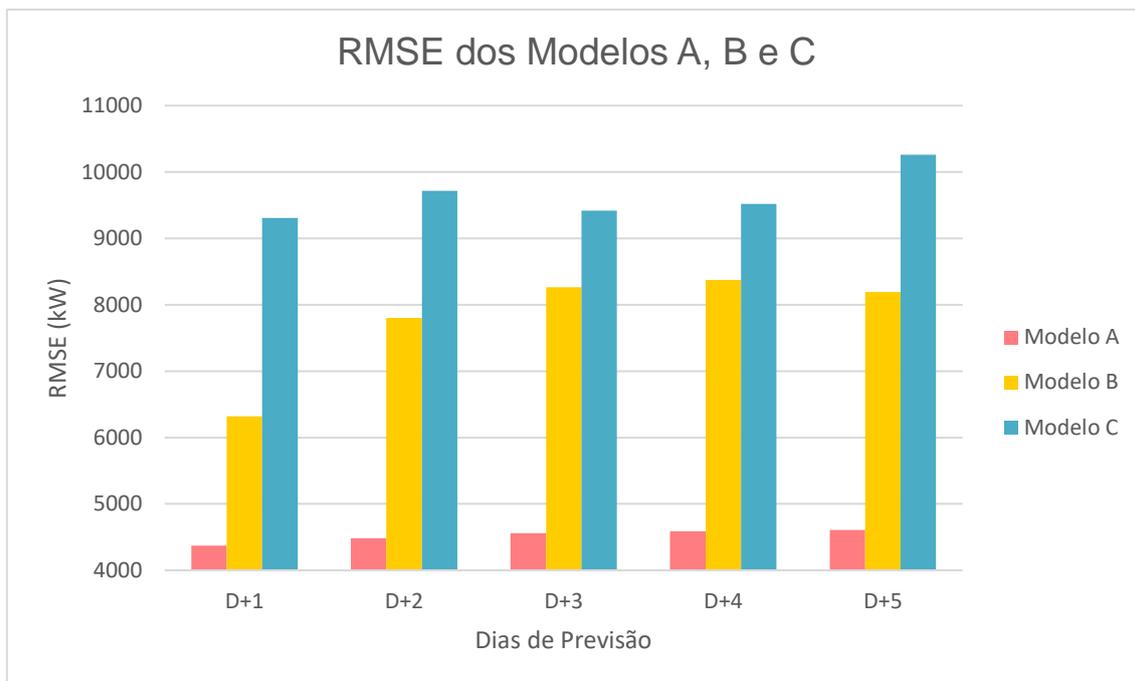


Figura 26. RMSE médio diário dos Modelos A, B e C por dias de previsão

Fonte: Elaboração própria

Foi analisada a melhora de acurácia das previsões para o Parque Modelo utilizando o Modelo A ao invés dos outros dois. Comparando com B, a melhora do RMSE foi de pelo menos 44%, enquanto o NMAPE foi de 73%. Já com o Modelo C, a melhora foi de pelo menos 106% de RMSE, e 151% para o NMAPE (Tabela 2).

Tabela 8. Melhora de performance utilizando o Modelo A

Dias de previsão	Modelo B		Modelo C	
	Rel. NMAPE (%)	Rel. RMSE (%)	Rel. NMAPE (%)	Rel. RMSE (%)
D+1	73,40	44,66	158,38	113,07
D+2	109,90	73,99	165,69	116,74
D+3	125,58	81,36	151,81	106,65
D+4	128,14	82,49	155,63	107,52
D+5	119,68	77,88	179,09	122,80

Foram feitos gráficos das previsões de doze, vinte e quatro, cinquenta e cem horas à frente ($H+t$, $t=12, 24, 50, 100$), para o período de teste em questão. Assim, foi possível analisar graficamente os resultados gerados de cada modelo. Os resultados estão ilustrados nas Figura 27 a 30.

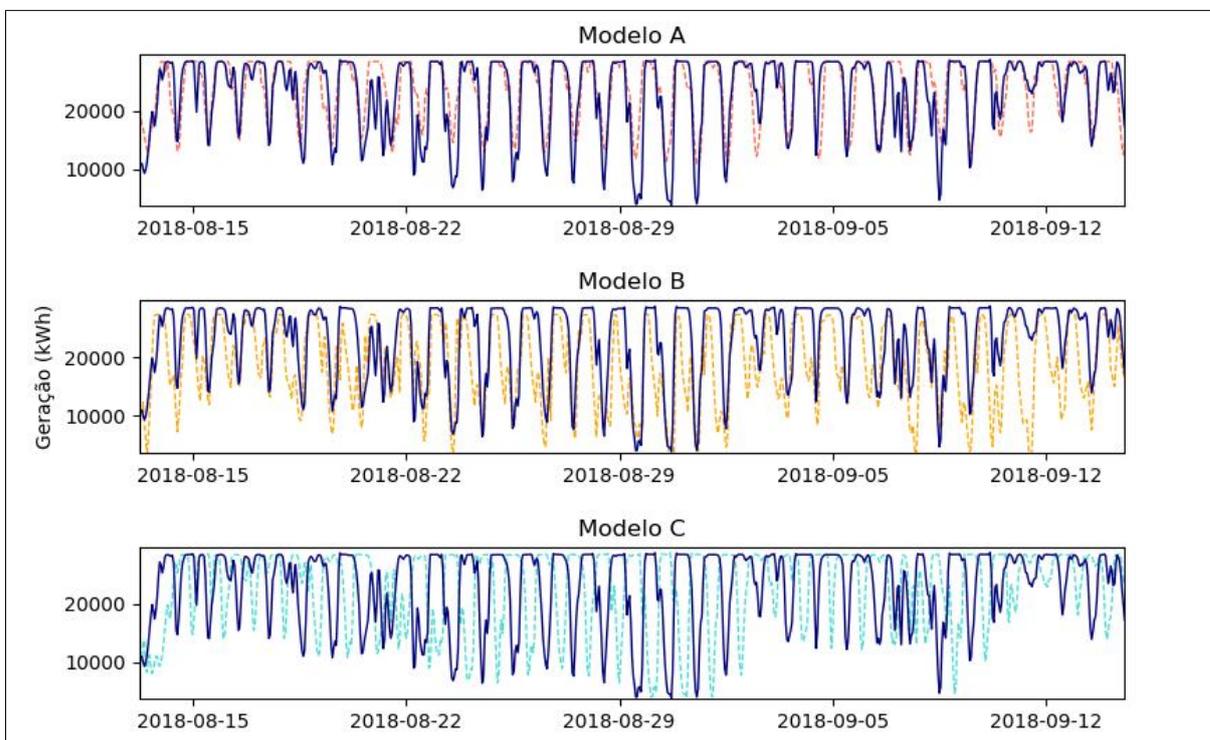


Figura 27. Previsões H+12 dos Modelos A, B e C de 13/08/2018 a 13/09/2018. Linhas pontilhadas são as previsões e a contínua e a geração medida.

Fonte: Elaboração própria

Pode-se inferir que o Modelo A apresenta maior correlação com os dados verificados de geração, enquanto o Modelo C apresenta uma diferença de fase de 12 horas, o que era esperado devido à metodologia aplicada. No entanto, para o H+24, o Modelo C apresentou melhor performance, pois, no período analisado, o comportamento do vento sofreu menos alterações a cada 24 horas.

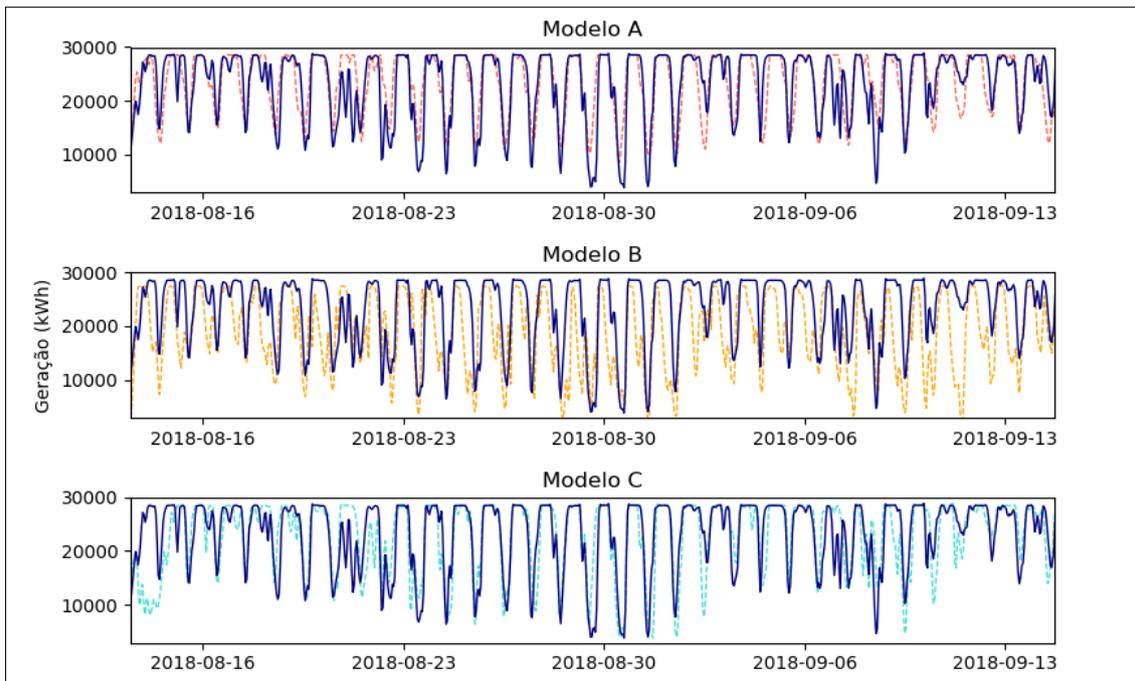


Figura 28. Previsões H+24 dos Modelos A, B e C de 13/08/2018 a 13/09/2018. Linhas pontilhadas são as previsões e a contínua e a geração medida.

Fonte: Elaboração própria.

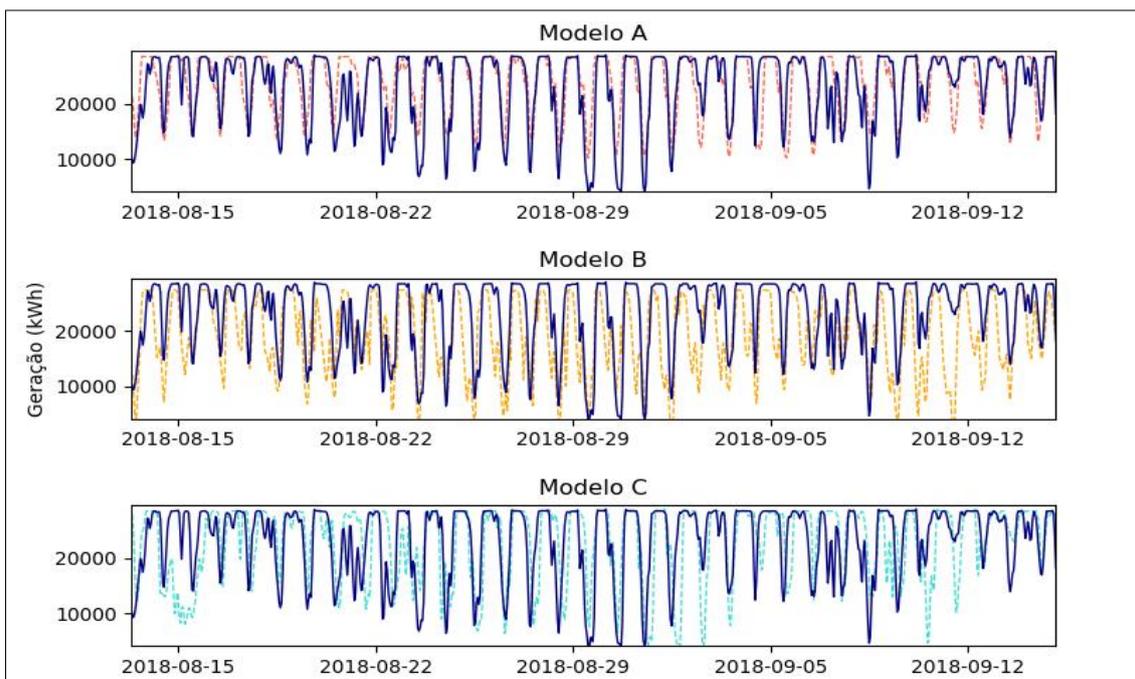


Figura 29. Previsões H+50 dos Modelos A, B e C de 13/08/2018 a 13/09/2018. Linhas pontilhadas são as previsões e a contínua e a geração medida.

Fonte: Elaboração própria.

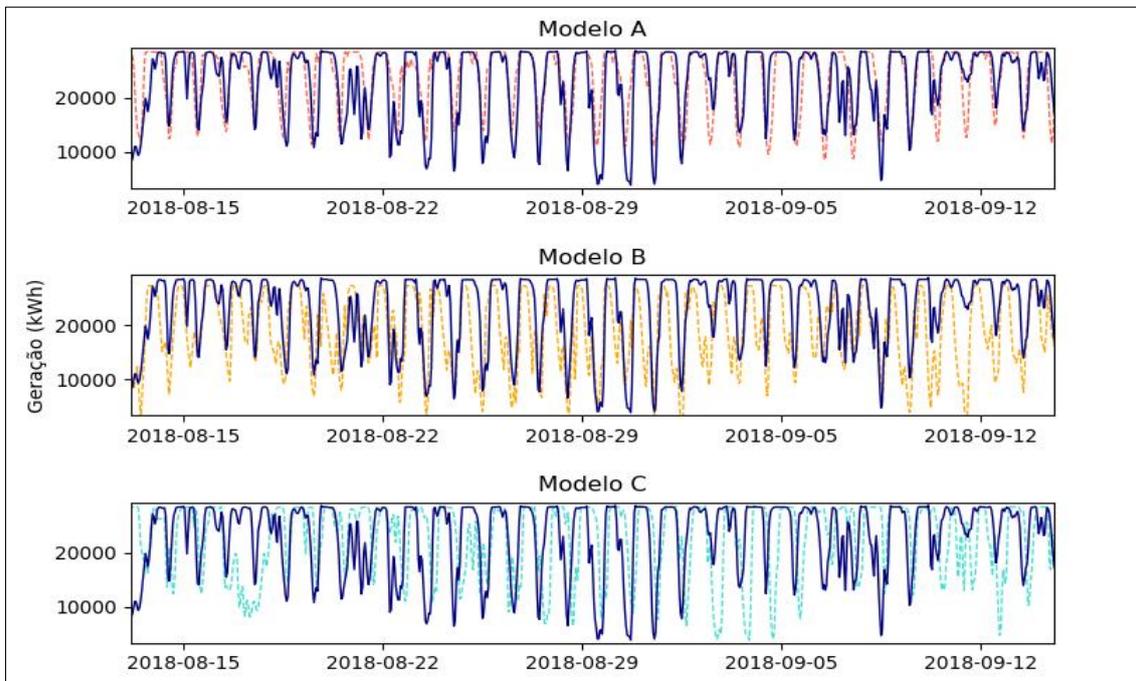


Figura 30. Previsões H+100 dos Modelos A, B e C de 13/08/2018 a 13/09/2018. Linhas pontilhadas são as previsões e a contínua e a geração medida.

Fonte: Elaboração própria.

5. Conclusões

Este trabalho buscou desenvolver e implementar um modelo para realizar previsões de geração de energia eólica utilizando o método da RNA. Paralelamente, um modelo físico e um de persistência foram implementados, possibilitando uma análise comparativa de desempenhos dos diferentes modelos. Todos os modelos foram desenvolvidos e aplicados com sucesso, uma vez que, os três foram capazes de gerar previsões para o Parque Modelo, juntamente com o trabalho de armazenamento do sistema de aquisição de dados.

Ao longo do estudo, verificou-se que o modelo baseado em RNA apresentou melhor desempenho em comparação com o modelo físico e o de persistência. O erro gerado pelo Modelo A também mostrou-se dentro das expectativas, apresentando um valor similar ao que se encontra na literatura (KARINIOTAKIS ET AL., 2004 e DE GIORGI et al., 2010). Para a primeira hora, o modelo apresentou erro de 4,36%, enquanto para um dia à frente, o valor foi de 10,15%, sendo este menor que o do modelo de persistência (até para previsões de curtíssimo prazo).

Contudo, a construção do modelo baseado em RNA mostrou-se mais trabalhosa, tendo diversos parâmetros a serem ajustados, como, por exemplo, a estrutura da rede e o arranjo dos dados de entrada. Numerosas análises prévias são necessárias antes da implementação do modelo.

Outro ponto negativo da RNA é demanda por dados para o treinamento da rede. É necessário que os dados obtidos tenham qualidade e que sejam representativos o suficiente para que o treinamento seja eficiente.

Sobre o modelo físico, percebe-se que as previsões estão subestimadas em relação aos dados medidos de geração. Isso pode ser explicado pela redução das maiores velocidades pela regressão linear, uma vez que o ajuste apresentou coeficiente angular menor que um. Assim, a regressão utilizada não se mostrou a melhor opção para a correção dos dados de previsão de vento gerados pelo modelo GFS. Também percebeu-se que o modelo desenvolvido tinha grande dependência do NCEP para a aquisição de dados de previsão de vento.

Um ponto relevante refere-se ao desempenho do modelo de persistência para um dia à frente. O parque eólico em questão não apresenta comportamento diário muito variado, portanto, previsões do Modelo C para D+1 apresentaram boa performance. No

entanto, não superior ao Modelo A. Pode-se ver pelos resultados que quando há um dia atípico, a persistência não consegue realizar previsões tão bem quanto os outros modelos.

Analisando as previsões, nota-se que o Modelo B consegue prever as variações mais bruscas melhor do que os outros dois modelos. Como exemplo, nos dias 21/08/2018 e 08/09/2018, houve quedas na geração de energia, divergindo do padrão que se configurava no período. Portanto, não se deve descartar um modelo de previsão por ele ter pior desempenho que outro, uma vez que, o mesmo pode apresentar informações que não são visíveis pelo modelo de menor erro. Conforme foi apresentado anteriormente, diversos trabalhos implementam modelos híbridos, buscando incorporar os melhores aspectos de cada metodologia.

Pode-se afirmar que o Modelo A pode ser utilizado para fins operacionais, uma vez que, obteve um bom desempenho nos testes realizados para usinas individuais. Como exemplo, as previsões podem ser utilizadas para operações de curto prazo no parque eólico e para programação de manutenções dos aerogeradores, otimizando a geração acumulada de energia da usina. Em nível nacional, as previsões também podem ser utilizadas pelos operadores do SIN, informando quais são os períodos de alta e baixa geração eólica, o que permite o controle e ação das hidrelétricas e térmicas de forma mais eficiente. No entanto, deve ser estudado a aplicação e reação do modelo para sistemas de larga escala (maiores que um parque eólico).

No presente trabalho, ressaltou-se a importância das previsões no setor eólico. Os riscos atribuídos à volatilidade do recurso são reduzidos com o conhecimento da futura geração dos parques. As operações destas usinas podem ser feitas de forma planejada e embasada em informações técnicas, o que aumenta a confiabilidade na energia eólica e, conseqüentemente, ajuda na inserção do modal nos sistemas elétricos.

Para trabalhos futuros, propõe-se o estudo da incorporação de previsões de vento como entrada da RNA, buscando melhorar a identificação de variações bruscas de geração de energia. Também sugere-se que sejam estudadas novas técnicas de ajustes do vento previsto para o modelo físico. Sabe-se que modelos numéricos podem ser utilizados para esta função, porém, requerem poder computacional que pode ser inviável para operações em tempo real. Por fim, propõe-se também a análise de modelos híbridos em comparação com modelos únicos, visto que o estudo deste conjunto é dificilmente encontrado na literatura.

6. Referência Bibliográfica

ABEEÓLICA, *Geração de energia eólica cresce 19% em 2018*, 2018. Disponível em: <<http://abeeolica.org.br/noticias/geracao-de-energia-eolica-cresce-19-em-2018/>>. Acesso em: 23 out. 2018.

NAÇÕES UNIDAS, *Acordo de Paris sobre o clima*. 2015. Disponível em: <<https://nacoesunidas.org/acordodeparis/>>. Acesso em: 03 dez. 2018.

ADEBAYO, A., OLATUBOSUN, O., TERHEMEN, O., *Predictive Sales Model using Multi-layer Neural Network with Backpropagation Algorithm*. International Journal of Engineering Technology, Management and Applied Sciences, v. 6, i. 4, pp. 30-40, 2018.

AMARAL, Bianca Mesquita. *Modelo VARX para geração de cenários de vento e vazão aplicados à comercialização de energia*. Dissertação (Mestrado), Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2011.

BEZERRA, E. C., BRAGA, A. P. S., LEÃO, R. P. S., “Comparação entre modelos estatísticos e redes neurais usando persistência como referência para a previsão da velocidade do vento”. *X SBAI – Simpósio Brasileiro de Automação Inteligente*, São João Del-Rei, 18-21 nov. 2011.

BP, *Energy Outlook 2017 Edition*, 2017. Disponível em: <<https://www.bp.com/content/dam/bp/pdf/energy-economics/energy-outlook-2017/bp-energy-outlook-2017.pdf>>. Acesso em: 23 nov. 2018.

BUSSAB, W. O., MORETTIN, P. A., *Estatística básica*. Saraiva, 6. ed., São Paulo, 2014.

CARMELO, H. N., CARVALHO, P. C. M., LEAL, J. B. V., et al., *Previsão de velocidade do vento no nordeste brasileiro através do modelo ARIMAX*. Revista Ciência e Tecnologia, v. 20, n. 36, pp. 9-17, 2017.

CASTRO, R., *Energias renováveis e produção descentralizada: introdução à energia eólica*. Universidade Técnica de Lisboa/ Instituto Superior Técnico, Lisboa, 2008.

DATA SCIENCE BLOG, *A quick introduction to neural networks*, 2016. Disponível em: <<https://ujjwalkarn.me/2016/08/09/quick-intro-neural-networks/>>. Acesso em: 27 nov. 2018.

DE GIORGI, M. G., FICARELLA, A., TARANTINO, M., *Error analysis of short-term wind power prediction models*. Applied Energy, v. 88, i. 4, pp. 1298-1311, 2011.

EPE - Empresa de Pesquisa Energética, “Projeção de demanda de energia elétrica para os próximos 10 anos (2017-2026)”. Nota técnica DEA, v. 3, pp. 15, 2017.

FREITAS, S. R., GUETTER, A. K., LIMA, J. M., et al., *A meteorological–statistic model for short-term wind power forecasting*. Journal of Control, Automation and Electrical Systems, v. 28, pp. 679-691, 2017.

GONZAGA, R., GURSKI, B., TENDOLINI, P., *Conferência de Estocolmo: um marco na questão ambiental*. Revista Uni Curitiba, v. 11, n. 12, 2012.

GWEC – GLOBAL WIND ENERGY COUNCIL, *Global Wind Report 2017*. 2017.

HAYKIN, S., *Neural networks - a comprehensive foundation*. Macmillan College Publishing Company, USA, NY - New York, 1994.

IEC, CDV. 61400-12-1: *Wind turbines—Part 12-1: Power performance measurements of electricity producing wind turbines*. Geneva, Suíça, 2005.

INFRAESTRUTURA URBANA, *Usina Eólica de Alegria I*, 2011. Disponível em: <<http://infraestruturaurbana17.pini.com.br/solucoes-tecnicas/6/artigo227165-2.aspx>>. Acesso em: 27 nov. 2018.

KARINIOTAKIS, G., MARTI, I., “What performance can be expected by short-term wind power prediction models depending on site characteristics?”. *EWEC’04 Conference*, Londres, 22-25 nov. 2004.

KARINIOTAKIS, G., MADSEN, H., NIELSEN, H. A., NIELSEN, T. S., PINSON, P., *A protocol for standardizing the performance evaluation of short term wind power prediction models*. Multi-science Publishing, v. 29, pp. 475-489, 2005.

LIMA, E. C., MOIZINHO, L. C. S., SANTOS, I. A., *Energia eólica no Brasil: oportunidades e limitações para o desenvolvimento sustentável*. Revista Estudo & Debate, Lajeado, v. 25, n. 1, 2018.

MELO, Marcelo Silva de Matos. *Energia eólica: aspectos técnicos e econômicos*. Dissertação (Mestrado), Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2012.

MESSTECHNIK, *Anemômetro first class advanced*. Disponível em: <http://www.messtechnik.com.br/_loja_/p/13728/anemometro-first-class-advanced--thies-clima>. Acesso em: 27 nov. 2018.

MICRO EÓLICA, *Limite de Betz*. Disponível em: <<https://microeolica.weebly.com/limite-de-betz.html>>. Acesso em: 27 nov. 2018.

NCEP, *The Global Forecast System (GFS) - Global Spectral Model (GSM)*, 2016. Disponível em: <<http://www.emc.ncep.noaa.gov/GFS/doc.php>>. Acesso em: 26 nov. 2018.

PORTAL ENERGIA, *Vantagens e desvantagens da energia eólica*, 2015. Disponível em: <<https://www.portal-energia.com/vantagens-desvantagens-da-energia-eolica/>>. Acesso em: 27 nov. 2018.

RUELA, A. S., *Treinamento e aprendizado em RNAs*, 2012. Disponível em: <http://www.decom.ufop.br/imobilis/wp-content/uploads/2012/06/02_Treinamento-e-Aprendizado-em-RNAs.pdf>. Acesso em: 26 nov. 2018.

SALINO, Pedro Jordão. *Energia eólica no Brasil: uma comparação do PROINFA e dos novos leilões*. Monografia (Graduação), Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2011.

SANTOS, T. F. F., *Previsão de potência eólica com base em modelos de prospecção de similaridade histórica*. Dissertação (Mestrado), Universidade do Porto, Porto, 2009.

TECNAL, *Anemômetro ultrassônico 3D*. Disponível em: <<http://tecnal.com.br/produtos/anemometro-ultrassonico-3d-windmaster-gill/>>. Acesso em: 27 nov. 2018.

VARGAS, Soraida Aguilar. *Previsão da distribuição da densidade de probabilidade da geração de energia eólica usando técnicas não paramétricas*. Tese (Doutorado), Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2015.

VELLASCO, M. M. B. R., *Redes Neurais Artificiais*, 2007. Disponível em: <<http://www2.ica.ele.puc-rio.br/Downloads/33/ICA-introdu%C3%A7%C3%A3o%20RNs.pdf>>. Acesso em: 26 nov. 2018.

WORLD ENERGY COUNCIL, *World energy resources – wind 2016*, 2016.
Disponível em: <https://www.worldenergy.org/wp-content/uploads/2017/03/WEResources_Wind_2016.pdf>. Acesso em: 26 nov. 2018.