



UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CAMPUS FLORIANÓPOLIS  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

João Gabriel de Farias

**MACHINE LEARNING APLICADO À PREVISÃO DE GERAÇÃO DE ENERGIA  
EÓLICA COM DIFERENTES MODELOS DE PREVISÃO NUMÉRICA DO TEMPO**

FLORIANÓPOLIS

2020

João Gabriel de Farias

**MACHINE LEARNING APLICADO À PREVISÃO DE GERAÇÃO DE ENERGIA  
EÓLICA COM DIFERENTES MODELOS DE PREVISÃO NUMÉRICA DO TEMPO**

Dissertação submetida ao Programa de Pós-Graduação  
em Engenharia Mecânica da Universidade Federal de  
Santa Catarina para a obtenção do título de Mestre em  
Engenharia Mecânica.

Orientador: Prof. Dr. Júlio César Passos

Coorientador: Prof. Dr. Reinaldo Haas

Florianópolis

2020

Ficha de identificação da obra elaborada pelo autor,  
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Farias, João Gabriel de  
MACHINE LEARNING APLICADO À PREVISÃO DE GERAÇÃO DE  
ENERGIA EÓLICA COM DIFERENTES MODELOS DE PREVISÃO NUMÉRICA  
DO TEMPO / João Gabriel de Farias ; orientador, Júlio  
César Passos, coorientador, Reinaldo Haas, 2020.  
158 p.

Dissertação (mestrado) - Universidade Federal de Santa  
Catarina, Centro Tecnológico, Programa de Pós-Graduação em  
Engenharia Mecânica, Florianópolis, 2020.

Inclui referências.

1. Engenharia Mecânica. 2. Previsão de Geração Eólica. 3.  
Modelos Numéricos de Previsão do Tempo. 4. Machine  
Learning. 5. Redes Neurais Artificiais. I. Passos, Júlio  
César. II. Haas, Reinaldo. III. Universidade Federal de  
Santa Catarina. Programa de Pós-Graduação em Engenharia  
Mecânica. IV. Título.

João Gabriel de Farias

**MACHINE LEARNING APLICADO À PREVISÃO DE GERAÇÃO DE ENERGIA  
EÓLICA COM DIFERENTES MODELOS DE PREVISÃO NUMÉRICA DO TEMPO**

O presente trabalho em nível de mestrado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Júlio César Passos, Dr.

Universidade Federal de Santa Catarina

Prof. João Carlos Espíndola Ferreira, Dr.

Universidade Federal de Santa Catarina

Prof. Mauro Augusto da Rosa, Dr.

Universidade Federal de Santa Catarina

Prof. Renato Ramos da Silva, Dr.

Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do Título de Mestre em Engenharia Mecânica pelo Programa de Pós-Graduação em Engenharia Mecânica.

---

Prof. Dr. Jonny Carlos da Silva

Coordenador do Programa

---

Prof. Dr. Júlio César Passos

Orientador

Prof. Dr. Reinaldo Haas

Coorientador

Florianópolis, 18 de fevereiro de 2020.

Dedico este trabalho aos meus familiares e a Deus.

## AGRADECIMENTOS

Agradeço a Deus por ter me dado sabedoria e energia para traçar minha trajetória.

Aos meus pais, João e Jane, pelo carinho e paciência ao longo da vida. Por me apoiarem em todos os momentos, me incentivarem a estudar, a buscar novos conhecimentos e a melhorar continuamente.

Ao Prof Júlio César Passos, meu orientador, por ter acreditado no meu trabalho, pela amizade e orientação durante o período de mestrado.

Ao Prof. Reinaldo Haas, meu coorientador, pela amizade, orientação e nossas longas conversas sobre os mais diversos temas.

À minha irmã pela amizade e por sempre estar presente quando preciso.

À minha companheira, Amanda, pela amizade, parceria, incentivo e ajuda.

Aos meus avós e familiares pelo apoio de sempre.

À Universidade Federal de Santa Catarina (UFSC), ao Programa de Pós-Graduação em Engenharia Mecânica (POSMEC-UFSC) e seus colaboradores por se dedicarem para prover um ensino de qualidade.

A todos os membros do Laboratório de Engenharia de Processos de Conversão e Tecnologia de Energia (LEPTEN/Boiling), pelo auxílio, parceria e bons momentos ao longo do desenvolvimento deste trabalho. Em especial gostaria de agradecer ao Fernando e Franciene.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio à pesquisa.

À empresa Atlantic Energias Renováveis S.A., por acreditar na parceria entre universidade e iniciativa privada, e estabelecer o projeto de P&D, no qual este trabalho se inseriu. E aos seus colaboradores Eduardo e Mayra pela troca de experiências nas reuniões de projeto.

A todos os membros do Engenheiro Sem Fronteiras – Núcleo Florianópolis, por fazerem parte do meu crescimento pessoal e profissional durante o período do desenvolvimento deste trabalho.

Ao Grupo de Oração Universitária (GOU) pelos momentos de comunhão e reflexão junto ao Espírito Santo.

À Sandrine Edouard por disponibilizar dados do Canadian Meteorological Centre (CMC).

A todos os amigos que fazem e fizeram parte de minha trajetória até o fim desta etapa.

“Nunca, jamais desanimeis, embora venham ventos contrários.”  
(Santa Paulina)

## RESUMO

Uma característica da energia eólica, inerente ao regime dos ventos, é a sua intermitência. Isto em conjunto com a elevada participação da energia eólica no Sistema Interligado Nacional (SIN) faz esta fonte de energia ser importante no planejamento do despacho energético pelo Operador Nacional do Sistema (ONS). Este requer a previsão de geração dos agentes geradores eólicos. Além disso, a previsão de geração é útil para o planejamento da Operação e Manutenção (O&M) do parque eólico, o que acarreta melhor aproveitamento desta fonte de energia e reduz as perdas - o que é muito importante no mercado altamente competitivo da energia renovável. O presente projeto teve por objetivo prever a geração de energia eólica no horizonte de 144 horas e resolução temporal de 10 minutos por meio de *machine learning* e diferentes modelos de previsão numérica do tempo para dois parques eólicos. O parque Ventos do Sertão (SER), no Complexo Eólico de Morrinhos no Nordeste, e o parque de Aura Mirim II (MIR-2), no Complexo Eólico de Santa Vitória do Palmar no Sul, ambos com 30 MW de capacidade instalada. Dois parques com características distintas em regiões distintas. Três métodos foram utilizados para a previsão de geração do parque eólico: o primeiro empregou a velocidade do vento mais próxima da altura do cubo proveniente de um modelo de previsão numérico do tempo e a curva de potência do aerogerador; o segundo utilizou a velocidade do vento prevista por meio de redes neurais artificiais e a curva de potência do aerogerador; e o terceiro previu o aerogerador equivalente médio, que é a média dos aerogeradores em funcionamento no parque, diretamente com redes neurais artificiais. Os dados de entrada dos métodos com redes neurais foram as variáveis dos modelos de previsão do tempo. A geração do parque foi obtida pela multiplicação da previsão com o número de aerogeradores aptos a funcionar naquele instante para o método que previu o aerogerador equivalente, enquanto que para o método com curva de potência apenas os aerogeradores em funcionamento tinham sua potência somada para a obtenção da geração do parque. Os modelos de previsão do tempo utilizados foram o *Global Forecast System* (GFS), *Global Deterministic Forecast System* (GDPS) e *Weather Research and Forecasting* (WRF), sendo os dois primeiros modelos globais e o último um modelo de mesoescala. A princípio, esperava-se que os métodos com o modelo de mesoescala WRF alcançassem os melhores resultados na comparação direta com os modelos globais, entretanto, isto não ocorreu. Outro fato importante é que os métodos com *machine learning* e variáveis provenientes de mais de um modelo de previsão do tempo conseguiram prever com maior acurácia na comparação com os métodos que possuíam apenas um modelo. O NRMSE da previsão de geração para o parque SER ficou em torno de 21 % e para o parque MIR-2 ficou em torno de 22 %.

**Palavras-chave:** Previsão de Geração Eólica; *Machine Learning*; Redes Neurais Artificiais; Modelos Numéricos de Previsão do Tempo; Multi-Modelos.

## ABSTRACT

An important factor in wind energy is its intermittency, as wind has this characteristic. This together with the high participation of wind energy in the National Interconnected System (SIN) makes this energy source important in the planning of energy dispatch by the National System Operator (ONS). This institution requires the wind power forecast from wind farm owners. In addition, wind power forecasting is useful for wind farm operation and maintenance (O&M) planning, which makes better use of this energy source and reduces losses - which is very important in the highly competitive renewable energy market. The present project aimed to predict wind power generation 144 hours ahead with time resolution of 10 minutes using machine learning and different numerical weather prediction models for two wind farms. The Ventos do Sertão wind farm (SER), in the Morrinhos Wind Complex in the Northeast, and the Aura Mirim II wind farm (MIR-2), in the Santa Vitória do Palmar Wind Complex in the South, both with 30 MW of installed capacity. Two wind farms with distinct characteristics in different regions. Three methods were used to predict wind farm generation: the first employed the wind speed closest to the hub height from a numerical weather prediction model and the wind turbine power curve; the second used the predicted wind speed by the artificial neural networks and the wind turbine power curve; and the third predicted the average equivalent wind turbine, which is the average of wind turbines operating in the wind farm, directly from artificial neural networks. The input data to the methods that have neural networks were the variables from the numerical weather prediction models. The wind farm power output was obtained from the multiplication of the forecast by the number of wind turbines able to work in the case of the method employing the equivalent wind turbine, whereas for the methods that employ wind turbine power curve only the wind turbines in operation had their power summed to obtain the wind farm power output. The numerical weather prediction models used were the Global Forecast System (GFS), the Global Deterministic Forecast System (GDPS) and the Weather Research and Forecasting (WRF), where the first two are global models and the last one is a mesoscale model. It was expected that schemes with WRF mesoscale model would achieve the best results in direct comparison with global models, however, it did not happen. Another important fact is that the machine learning methods and variables from more than one numerical weather prediction model were able to predict more accurately compared to methods that had only one model. The NRMSE of the wind power forecast for the SER wind farm was around 21 % and for the MIR-2 wind farm it was around 22 %.

**Keywords:** Wind Power Forecasting; Machine Learning; Artificial Neural Network; Numerical Weather Prediction Models; Multi-Models.

## LISTA DE FIGURAS

Figura 1 - Padrão global de circulação dos ventos.....	19
Figura 2 - Volume de controle que representa o escoamento de ar sobre uma turbina eólica.....	21
Figura 3 - Exemplo de underfitting, capacidade apropriada e overfitting em um conjunto de dados de treinamento gerado sinteticamente. ....	24
Figura 4 - Exemplos de funções de ativação para os neurônios das camadas escondidas. ....	25
Figura 5 - Modelo matemático de um neurônio artificial. ....	27
Figura 6 - Esquema de uma rede neural multicamadas perceptron ( <i>Multilayer Perceptron</i> –MLP), que é uma rede neural alimentada adiante ( <i>feedforward neural network</i> ) densa, onde as setas indicam o sentido da informação.....	27
Figura 7 - Diagrama de Venn com as relações entre <i>deep learning</i> , <i>machine learning</i> e inteligência artificial. ....	28
Figura 8 - Figura de auxílio para explicar as diferentes abordagens de previsão. ....	31
Figura 9 - Localização dos parques eólicos de Sertão (SER) e Aura Mirim II (MIR-2). ....	43
Figura 10 –Vista de erogeradores do Complexo Eólico de Morrinhos.....	45
Figura 11 - Complexo de Morrinhos com aerogeradores e torre de referência (AC7402) do parque Sertão (SER) em destaque. ....	46
Figura 12 - Rosa dos ventos da torre AC7402 com velocidade normalizada pela velocidade média, construída com dados dos anos de 2017 e 2018.....	46
Figura 13 - Aerogeradores do Complexo Eólico de Santa Vitória do Palmar. ....	48
Figura 14 - Complexo de Santa Vitória do Palmar com aerogeradores e torre de referência (AC5312) do parque Aura Mirim II (MIR-2) em destaque.....	48
Figura 15 - Rosa dos ventos da torre AC5312 com velocidade normalizada pela velocidade média, construída com dados dos anos de 2017 e 2018.....	49
Figura 16 - Grade do GFS (0,25°) sobre o Complexo Eólico de Morrinhos com destaque em vermelho para a torre de referência do parque Sertão (AC7402).....	50
Figura 17 - Grade do GFS (0,25°) sobre o Complexo Eólico de Santa Vitória do Palmar com destaque em vermelho para a torre de referência do parque Aura Mirim II (AC5312). ..	51

Figura 18 - Grade do GDPS (0,24°) sobre o CEMOR com destaque para o a torre de referência do parque SER. ....	52
Figura 19 - Grade do GDPS (0,24°) sobre o CESVP com destaque para o a torre de referência do parque MIR-2. ....	52
Figura 20 - (a) Grade do domínio d01 (12 km) e d02 (4km) sobre CEMOR; (b) Pontos de grade ao redor da torre de referência do parque Sertão. ....	54
Figura 21 - (a) Grade do domínio d01 (12 km) e d02 (4km) sobre CESVP; (b) Pontos de grade ao redor da torre de referência do parque Aura Mirim II. ....	55
Figura 22 - Fluxograma do método físico de previsão de geração. ....	57
Figura 23 - Fluxograma do método de previsão de geração que utiliza redes neurais artificiais para prever a velocidade do vento na altura do cubo e na posição da torre. ....	59
Figura 24 - Fluxograma do método de previsão de geração que utiliza redes neurais artificiais para prever a potência gerada pelo aerogerador equivalente médio.....	59
Figura 25 - Representação da validação cruzada <i>walking forward</i> .....	61
Figura 26 - Exemplo do diagrama de Taylor com a representação estatística de três modelos.....	62
Figura 27 - Esquemas a serem testados com os métodos de previsão de geração eólica, onde NWP remete a um dos modelos de previsão numérica do tempo (GFS, GDPS ou WRF). ....	63
Figura 28 - Série temporal da velocidade do vento medida, em médias de dez minutos, e da prevista pelos diferentes modelos NWP para o parque de Sertão.....	71
Figura 29 - Série temporal da velocidade do vento medida, em médias de dez minutos, e da prevista pelos diferentes modelos NWP para o parque de Aura Mirim II. ....	72
Figura 30 - Série temporal da geração medida e da prevista pelo método físico, esquema 1, com os diferentes modelos NWP para o parque eólico Ventos do Sertão. ....	73
Figura 31 - Representação das séries temporais da previsão de geração do parque eólico Ventos do Sertão pelo esquema 1, com o método físico, em um diagrama de Taylor. .	74
Figura 32 - Série temporal da geração medida e da prevista pelo método físico, esquema 1, com os diferentes modelos NWP para o parque eólico de Aura Mirim II. ....	75
Figura 33 - Representação das séries temporais da previsão de geração do parque eólico Aura Mirim II pelo esquema 1, com o método físico, em um diagrama de Taylor.....	76
Figura 34 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq_2) com os diferentes grupos de variáveis do GFS e redes neurais com uma	

camada escondida (MLP1) que prevêem a velocidade do vento na altura do cubo para a torre de referência do parque Ventos do Sertão. ....	78
Figura 35 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq_2) com os diferentes grupos de variáveis do GFS e redes neurais com duas camadas escondidas (MLP2) que prevêem a velocidade do vento na altura do cubo para a torre de referência do parque Ventos do Sertão. ....	78
Figura 36 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq_2) com os diferentes grupos de variáveis do GFS e redes neurais com três camadas escondidas (MLP3) que prevêem a velocidade do vento na altura do cubo para a torre de referência do parque Ventos do Sertão. ....	79
Figura 37 - Série temporal da velocidade do vento em médias de dez minutos medida e da prevista pelas melhores topologias das redes neurais dos esquemas 2, 3 e 4 para o Parque Ventos do Sertão, na altura de 78 m. ....	86
Figura 38 - Geração real do parque Ventos do Sertão e prevista pelo método com redes neurais que prevê a velocidade do vento com a melhor topologia e conjunto de variáveis de cada esquema de previsão. ....	88
Figura 39 - Representação estatística da previsão de geração pelas melhores topologias e conjunto de variáveis dos esquemas de previsão que utilizam o método com <i>machine learning</i> que prevê a velocidade do vento com redes neurais artificiais para o parque Ventos do Sertão. ....	90
Figura 40 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq_2) com os diferentes grupos de variáveis do GFS e redes neurais com uma camada escondida (MLP1) que prevêem a velocidade do vento na altura do cubo para a torre de referência do parque Aura Mirim II. ....	91
Figura 41 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq_2) com os diferentes grupos de variáveis do GFS e redes neurais com duas camadas escondidas (MLP2) que prevêem a velocidade do vento na altura do cubo para a torre de referência do parque Aura Mirim II. ....	91
Figura 42 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq_2) com os diferentes grupos de variáveis do GFS e redes neurais com três camadas escondidas (MLP3) que prevêem a velocidade do vento na altura do cubo para a torre de referência do parque Aura Mirim II. ....	92

Figura 43 - Série temporal da velocidade do vento em médias de dez minutos medida e da prevista pelas melhores topologias das redes neurais dos esquemas 2, 3 e 4 para o parque Aura Mirim II. ....	100
Figura 44 - Geração real do parque Aura Mirim II e prevista pelo método com redes neurais que prevê a velocidade do vento com a melhor topologia e conjunto de variáveis de cada esquema de previsão.....	102
Figura 45 - Representação estatística da previsão de geração pelas melhores topologias e conjunto de variáveis dos esquemas de previsão que utilizam o método com <i>machine learning</i> que prevê a velocidade do vento com redes neurais artificiais para o parque Aura Mirim II. ....	104
Figura 46 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq_2) com os diferentes grupos de variáveis do GFS e redes neurais com uma camada escondida (MLP1) que prevêem a geração do aerogerador equivalente médio do parque Ventos do Sertão.....	105
Figura 47 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq_2) com os diferentes grupos de variáveis do GFS e redes neurais com duas camadas escondidas (MLP2) que prevêem a geração do aerogerador equivalente médio do parque Ventos do Sertão.....	106
Figura 48 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq_2) com os diferentes grupos de variáveis do GFS e redes neurais com três camadas escondidas (MLP3) que prevêem a geração do aerogerador equivalente médio do parque Ventos do Sertão.....	106
Figura 49 - Série temporal da geração do aerogerador equivalente médio em médias de dez minutos real (Aero Eq) e previsto pelas melhores topologias das redes neurais dos esquemas 2, 3 e 4 para o parque Ventos do Sertão.....	114
Figura 50 - Geração real do parque Ventos do Sertão e prevista pelo método com redes neurais que prevêem a geração do aerogerador equivalente médio com a melhor topologia e conjunto de variáveis de cada esquema de previsão.....	115
Figura 51 - Representação estatística da previsão de geração pelas melhores topologias e conjunto de variáveis dos esquemas de previsão que utilizam o método com <i>machine learning</i> que prevê a geração do aerogerador equivalente médio com redes neurais artificiais para o parque Ventos do Sertão.....	117
Figura 52 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq_2) com os diferentes grupos de variáveis do GFS e redes neurais com uma	

camada escondida (MLP1) que prevêem a geração do aerogerador equivalente médio do parque Aura Mirim II. ....	118
Figura 53 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq_2) com os diferentes grupos de variáveis do GFS e redes neurais com duas camadas escondidas (MLP2) que prevêem a geração do aerogerador equivalente médio do parque Aura Mirim II. ....	118
Figura 54 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq_2) com os diferentes grupos de variáveis do GFS e redes neurais com três camadas escondidas (MLP3) que prevêem a geração do aerogerador equivalente médio do parque Aura Mirim II. ....	119
Figura 55 - Série temporal da geração do aerogerador equivalente médio em médias de 10 min real (Aero Eq) e prevista pelas melhores topologias das redes neurais dos esquemas 2, 3 e 4 para o parque Aura Mirim II. ....	127
Figura 56 - Geração real do parque Aura Mirim II e prevista pelo método com redes neurais que prevêem a geração do aerogerador equivalente médio com a melhor topologia e conjunto de variáveis de cada esquema de previsão. ....	128
Figura 57 - Representação estatística da previsão de geração pelas melhores topologias e conjunto de variáveis dos esquemas de previsão que utilizam o método com <i>machine learning</i> que prevê a geração do aerogerador equivalente médio com redes neurais artificiais para o parque Aura Mirim II. ....	129
Figura 58 - Métricas de performance dos representantes de cada método para o parque Ventos do Sertão. ....	132
Figura 59 - NRMSE calculado a cada dia (gráfico de barras) e NRMSE acumulado conforme o horizonte de previsão aumenta (gráfico de linha) para os diferentes métodos de previsão de geração do parque Ventos do Sertão. ....	134
Figura 60 - Séries temporais da geração medida e prevista pelos representantes de cada método para o parque Ventos do Sertão. ....	134
Figura 61 - Geração medida e prevista pelos representantes de cada método para o parque Ventos do Sertão entre o dia 15/02/2018 e o final de 20/02/2018, ciclo 8 da Tabela 8. ....	135
Figura 62 - Representação estatística pelo diagrama de Taylor dos representantes dos métodos de previsão de geração para o parque Ventos do Sertão. ....	136

Figura 63 - Métricas de performance dos representantes de cada método para o parque Aura Mirim II. ....	138
Figura 64 - NRMSE calculado a cada dia (gráfico de barras) e NRMSE acumulado conforme o horizonte de previsão aumenta (gráfico de linha) para os diferentes métodos de previsão de geração do parque Aura Mirim II.....	140
Figura 65 - Séries temporais da geração medida e prevista pelos representantes de cada método para o parque Aura Mirim II.....	140
Figura 66 - Geração medida e prevista pelos representantes de cada método para o parque Aura Mirim II entre o dia 15/02/2018 e o final de 20/02/2018, ciclo 8 da Tabela 7..	141
Figura 67 - Representação estatística pelo diagrama de Taylor dos representantes dos métodos de previsão de geração para o parque Aura Mirim II. ....	142

## LISTA DE TABELAS

Tabela 1- Síntese de resultados de artigos citados na seção 2.5.....	38
Tabela 2 - Alturas dos instrumentos na torre anemométrica de medição do parque SER. .....	44
Tabela 3 - Alturas dos instrumentos na torre anemométrica de medição do parque MIR-2. ....	47
Tabela 4 - Equações para mensurar o erro de um modelo de previsão. ....	60
Tabela 5 - Informações sobre os modelos de NWP utilizados no estudo. ....	64
Tabela 6 - Variáveis testadas de cada modelo NWP testadas com os esquemas de previsão de geração. ....	65
Tabela 7 - Hiperparâmetros empregados nas redes neurais MLP testadas. ....	67
Tabela 8 - Bancos de dados de treino e teste em cada ciclo da validação cruzada. ...	68
Tabela 9 - Números de variáveis obtidos pelo método de seleção por meio do coeficiente de Pearson para: a velocidade do vento na torre anemométrica de referência e altura do cubo; e para o aerogerador equivalente médio. ....	69
Tabela 10 - Métricas de erro para previsão de velocidade pelos modelos NWP para o parque Ventos do Sertão.....	71
Tabela 11 - Métricas de erro para previsão de velocidade pelos modelos NWP para o parque de Aura Mirim II.....	72
Tabela 12 - Métricas de erro para previsão de geração do parque eólico Ventos do Sertão pelo esquema 1, com o método físico. ....	74
Tabela 13 - Métricas de erro para previsão de geração do parque eólico de Aura Mirim II pelo esquema 1, com o método físico.....	75
Tabela 14 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que preveem a velocidade do vento no esquema 2 (Esq_2) com variáveis do GFS para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.....	79
Tabela 15 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que preveem a velocidade do vento no esquema 2 (Esq_2) com variáveis do GDPS para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.....	80

Tabela 16 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a velocidade do vento no esquema 2 (Esq_2) com variáveis do WRF-d01 para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.....	81
Tabela 17 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a velocidade do vento no esquema 2 (Esq_2) com variáveis do WRF-d02 para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.....	82
Tabela 18 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a velocidade do vento no esquema 3 (Esq_3) com variáveis do GFS e GDPS para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.....	83
Tabela 19 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a velocidade do vento no esquema 4 (Esq_4) com variáveis do GFS, GDPS e WRF-d01 para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.....	85
Tabela 20 - Melhores topologias das redes neurais que preveem a velocidade do vento para os esquemas 2, 3 e 4 do parque Ventos do Sertão.....	86
Tabela 21 - Métricas de erro para previsão da velocidade pelas redes neurais dos esquemas de previsão com <i>machine learning</i> para o parque Ventos do Sertão.....	87
Tabela 22 - Métricas de erro das previsões de geração do parque Ventos do Sertão pelas melhores topologias e conjunto de variáveis dos esquemas que empregaram redes neurais na previsão da velocidade do vento.....	88
Tabela 23 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a velocidade do vento no esquema 2 (Esq_2) com variáveis do GFS para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.....	92
Tabela 24 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a velocidade do vento no esquema 2 (Esq_2) com variáveis do GDPS para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.....	94
Tabela 25 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a velocidade do vento no esquema 2 (Esq_2)	

com variáveis do WRF-d01 para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.....	95
Tabela 26 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a velocidade do vento no esquema 2 (Esq_2) com variáveis do WRF-d02 para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.....	96
Tabela 27 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a velocidade do vento no esquema 3 (Esq_3) com variáveis do GFS e GDPS para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.....	97
Tabela 28 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a velocidade do vento no esquema 4 (Esq_4) com variáveis do GFS, GDPS e WRF-d01 para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida. ....	98
Tabela 29 - Melhores topologias das redes neurais que preveem a velocidade do vento para os esquemas 2, 3 e 4 do parque Aura Mirim II.....	99
Tabela 30 - Métricas de erro para previsão da velocidade pelas redes neurais dos esquemas de previsão com <i>machine learning</i> para o parque Aura Mirim II.....	101
Tabela 31 - Métricas de erro das previsões de geração do parque Aura Mirim II pelas melhores topologias e conjunto de variáveis dos esquemas que empregaram redes neurais na previsão da velocidade do vento.....	103
Tabela 32 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 2 (Esq_2) com variáveis do GFS para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.....	107
Tabela 33 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 2 (Esq_2) com variáveis do GDPS para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.....	108
Tabela 34 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 2 (Esq_2) com variáveis do WRF-d01 para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida. ....	109

Tabela 35 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 2 (Esq_2) com variáveis do WRF-d02 para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida. ....	110
Tabela 36 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 3 (Esq_3) com variáveis do GFS e GDPS para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida. ....	111
Tabela 37 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 4 (Esq_4) com variáveis do GFS, GDPS e WRF-d01 para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida. ....	112
Tabela 38 - Melhores topologias das redes neurais que prevêm a geração do aerogerador equivalente médio para os esquemas 2, 3 e 4 do parque Ventos do Sertão. ....	113
Tabela 39 - Métricas de erro para previsão da geração do aerogerador equivalente médio pelas redes neurais dos esquemas de previsão com <i>machine learning</i> para o parque Ventos do Sertão.....	115
Tabela 40 - Métricas de erro das previsões de geração do parque Ventos do Sertão pelas melhores topologias e conjunto de variáveis dos esquemas que empregaram redes neurais na previsão da geração do aerogerador equivalente médio. ....	116
Tabela 41 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 2 (Esq_2) com variáveis do GFS para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida. ....	119
Tabela 42 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 2 (Esq_2) com variáveis do GDPS para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida. ....	121
Tabela 43 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 2 (Esq_2) com variáveis do WRF-d01 para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida. ....	122
Tabela 44 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio	

no esquema 2 (Esq_2) com variáveis do WRF-d02 para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida. ....	123
Tabela 45 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 3 (Esq_3) com variáveis do GFS e GDPS para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida. ....	124
Tabela 46 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 4 (Esq_4) com variáveis do GFS, GDPS e WRF-d01 para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida. ....	125
Tabela 47 - Melhores topologias das redes neurais que prevêm a geração do aerogerador equivalente médio para os esquemas 2, 3 e 4 do parque Aura Mirim II. ....	126
Tabela 48 - Métricas de erro para previsão da geração do aerogerador equivalente médio pelas redes neurais dos esquemas de previsão com <i>machine learning</i> para o parque Aura Mirim II. ....	127
Tabela 49 - Métricas de erro das previsões de geração do parque Aura Mirim II pelas melhores topologias e conjunto de variáveis dos esquemas que empregaram redes neurais na previsão da geração do aerogerador equivalente médio. ....	128
Tabela 50 - Representantes de cada método para o parque Ventos do Sertão. ....	130
Tabela 51 – Melhora dos modelos com <i>machine learning</i> em relação ao método base, método físico, para o parque Ventos do Sertão. ....	132
Tabela 52 - Representantes de cada método para o parque Aura Mirim II. ....	137
Tabela 53 – Melhora dos modelos com <i>machine learning</i> em relação ao método base, método físico, para o parque Aura Mirim II. ....	138

## LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
AR	<i>Autoregressive mode</i>
ARIMA	<i>Autoregressive Integrated Moving Average model</i>
ARMA	<i>Autoregressive Moving model</i>
BA	Bahia
BRAMS	<i>Brazilian Developments on the Regional Atmospheric Modelling System</i>
CEMOR	Complexo Eólico de Morrinhos
CESVP	Complexo Eólico Santa Vitória do Palmar
CMC	<i>Canadian Meteorological Centre</i>
CNN	Redes neurais convolucionais
COP 21	21ª Conferência da ONU sobre Mudanças Climáticas
COSMO-LEPS	<i>Limited-area Ensemble Prediction System developed within Consortium for Small-scale MOdelling</i>
DBN	<i>Deep Belief Networks</i>
DNN	<i>Deep neural networks</i>
ECMWF	<i>European Centre for Medium-Range Weather Forecast</i>
ECMWF EPS	<i>Ensemble Prediction System in use at the European Centre for Medium-Range Weather Forecasts</i>
EPE	Empresa de Pesquisa Energética
ESE	Leste-Sudeste
GDPS	Previsão determinística global, (na sigla em inglês <i>Global Deterministic Forecast</i> )
GFS	Sistema global de previsão, (na sigla em inglês <i>Global Forecast System</i> )
GWEC	<i>Global Wind Energy Council</i>
HRES	<i>High Resolution Model</i>
IA	Inteligência artificial
MA	<i>Moving average model</i>
MAE	Erro absoluto médio
MIR-2	Parque eólico Aura Mirim II

MLP	Rede neural multicamada perceptron
MME	Ministério de Minas e Energia
MRI	<i>Meteorological Risk Index</i>
NCAR	<i>National Center for Atmospheric Research</i>
NCEP	<i>National Center for Environmental Prediction</i>
NMAE	Erro absoluto médio normalizado
NMB	Erro médio normalizado
NNO	Nornoroeste
NOAA	<i>National Oceanic and Atmospheric Administration</i>
NOGAPS	<i>Navy Operational Global Prediction System</i>
NRMSD	Raiz da diferença quadrática média centrada normalizada
NRMSE	Raiz do erro quadrático médio normalizado, (na sigla em inglês <i>Normalized Root Mean Square Error</i> )
NWP	Modelo de previsão numérica do tempo
O&M	Operação e Manutenção
ONS	Operador Nacional do Sistema
ONU	Organização das Nações Unidas
P&D	Pesquisa e Desenvolvimento
ReLU	Função <i>Rectified Linear Unit</i>
RMSD	Raiz da diferença quadrática média centrada
RMSE	Raiz do erro quadrático médio
RNA	Rede neural artificial
RS	Rio Grande do Sul
SCADA	<i>Supervisory Control and Data Acquisition</i>
SDAE	<i>Stacked Denoising Autoencoder</i>
SER	Parque eólico Ventos do Sertão
SGD	Gradiente Descendente Estocástico
SIN	Sistema Interligado Nacional
SO	Sudoeste
SVM	Máquinas de vetores de suporte
tanh	Função tangente hiperbólica
USGS	<i>United States Geological Survey</i>
UTC	Tempo Universal Coordenado

WRF

Pesquisa e previsão do tempo, (na sigla em inglês *Weather Research and Forecasting*)

YSU

*Yonsei University*

## LISTA DE SÍMBOLOS

$P_w$	Potência disponível no vento, W
$\rho$	Massa específica do ar, kg/m <sup>3</sup>
$A$	Área varrida pelo rotor, m <sup>2</sup>
$U$	Componente U da velocidade do vento, m/s
$V$	Componente V da velocidade do vento, m/s
$W$	Componente W da velocidade do vento, m/s
$T$	Temperatura, °C
$d$	Direção do vento
$P$	Pressão atmosférica
$r$	Coefficiente de correlação de Pearson
$\mu$	Média dos dados
$\sigma$	Desvio padrão
$P_{t+k}$	Potência medida no instante t+k
$\hat{P}_{t+k t}$	Potência prevista para o instante t+k obtida por uma previsão realizada no tempo inicial t
$N$	Potência nominal do aerogerador ou do parque eólico no caso do erro para potência e a velocidade média no caso para velocidade do vento
$P_N$	
$e_{t+k t}$	Erro de previsão
$Imp_{EC,k}$	Melhora do modelo em relação à referência
EC	Critério de avaliação utilizado
$cov$	Covariância
$var$	Variância
$u_*$	Velocidade de fricção
UR	Umidade relativa

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>15</b>
1.1	APRESENTAÇÃO DO PROBLEMA.....	15
1.2	OBJETIVOS.....	17
1.3	ESTRUTURA DO TRABALHO .....	18
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA.....</b>	<b>19</b>
2.1	ENERGIA EÓLICA.....	19
2.2	MODELOS DE PREVISÃO NUMÉRICA DO TEMPO .....	21
2.3	MACHINE LEARNING .....	23
<b>2.3.1</b>	<b>Redes neurais artificiais .....</b>	<b>24</b>
<b>2.3.2</b>	<b>Deep learning .....</b>	<b>28</b>
2.4	MODELOS DE PREVISÃO DE GERAÇÃO EÓLICA .....	29
<b>2.4.1</b>	<b>Fatores que influenciam a acurácia de modelos de previsão de geração eólica .</b>	<b>32</b>
<b>2.4.2</b>	<b>Melhorias na previsão de geração eólica .....</b>	<b>34</b>
2.5	MACHINE LEARNING APLICADO À PREVISÃO DE GERAÇÃO EÓLICA....	34
2.6	SÍNTESE DOS RESULTADOS .....	38
<b>3</b>	<b>METODOLOGIA .....</b>	<b>43</b>
3.1	DESCRIÇÃO DOS PARQUES EÓLICOS .....	43
<b>3.1.1</b>	<b>Parque eólico Ventos do Sertão.....</b>	<b>44</b>
<b>3.1.2</b>	<b>Parque eólico Aura Mirim II.....</b>	<b>46</b>
3.2	MODELOS DE PREVISÃO NUMÉRICA DO TEMPO .....	49
<b>3.2.1</b>	<b>GFS 0,25°.....</b>	<b>49</b>
<b>3.2.2</b>	<b>GDPS 0,24 °.....</b>	<b>51</b>
<b>3.2.3</b>	<b>WRF.....</b>	<b>53</b>
3.3	SELEÇÃO DE VARIÁVEIS .....	55
3.4	CÁLCULO DO AEROGERADOR EQUIVALENTE MÉDIO .....	56
3.5	PREVISÃO DE GERAÇÃO EÓLICA NO MÉDIO PRAZO .....	56

3.5.1	<b>Método físico</b> .....	<b>56</b>
3.5.2	<b>Métodos com <i>machine learning</i></b> .....	<b>58</b>
3.5.2.1	Método de previsão de geração com a velocidade obtida por redes neurais artificiais .....	58
3.5.2.2	Método de previsão de geração com o aerogerador equivalente médio obtido por redes neurais artificiais.....	59
3.6	<b>AVALIAÇÃO DAS PREVISÕES</b> .....	<b>59</b>
3.6.1	<b>Cálculos de erro</b> .....	<b>59</b>
3.6.2	<b>Validação cruzada</b> .....	<b>60</b>
3.6.3	<b>Diagrama de Taylor</b> .....	<b>61</b>
3.7	<b>PROCEDIMENTO DE PESQUISA</b> .....	<b>62</b>
4	<b>RESULTADOS</b> .....	<b>69</b>
4.1	<b>SELEÇÃO DE VARIÁVEIS</b> .....	<b>69</b>
4.2	<b>PREVISÃO DE GERAÇÃO EÓLICA DO PARQUE PELO MÉTODO FÍSICO</b> ....	<b>70</b>
4.2.1	<b>Previsão de velocidade pelos modelos NWP</b> .....	<b>70</b>
4.2.2	<b>Previsão de geração do parque eólico pelo esquema 1</b> .....	<b>73</b>
4.3	<b>PREVISÃO DE GERAÇÃO PELOS MÉTODOS COM MACHINE LEARNING</b> .	<b>76</b>
4.3.1	<b>Previsão com redes neurais artificiais da velocidade do vento</b> .....	<b>77</b>
4.3.2	<b>Previsão com redes neurais artificiais do aerogerador equivalente médio</b> .....	<b>104</b>
4.4	<b>COMPARAÇÃO ENTRE OS MÉTODOS</b> .....	<b>130</b>
5	<b>CONCLUSÕES E RECOMENDAÇÕES</b> .....	<b>143</b>
5.1	<b>CONCLUSÕES</b> .....	<b>143</b>
5.2	<b>SUGESTÕES PARA TRABALHOS FUTUROS</b> .....	<b>146</b>
	<b>REFERÊNCIAS</b> .....	<b>147</b>
	<b>APÊNDICE A – Coordenadas dos aerogeradores</b> .....	<b>154</b>
	<b>APÊNDICE B – Variáveis de entrada para os métodos com <i>machine learning</i></b> .....	<b>156</b>



# 1 INTRODUÇÃO

## 1.1 APRESENTAÇÃO DO PROBLEMA

O progresso econômico tem gerado crescente demanda de energia, que tem sido suprida, nos últimos 140 anos, majoritariamente por combustíveis fósseis. Como consequência, o acúmulo de dióxido de carbono, na atmosfera terrestre, já ultrapassou a concentração de 400 ppm (partes por milhão), com impacto no aquecimento global atribuído a causas antropogênicas. Com o intuito de modificar a situação atual, 186 países em 2015 firmaram um acordo, durante a COP 21 (Conferência da Organização das Nações Unidas (ONU) sobre Mudanças Climáticas, em Paris), para reduzir as emissões de gases do efeito estufa. Essa transição será alcançada com o auxílio de fontes de energia renovável, dentre elas a energia eólica se destaca por ter um mercado amadurecido e um preço competitivo em relação às fontes tradicionais.

Ao final de 2017 havia aproximadamente 539 GW em capacidade instalada de energia eólica no mundo. E mais de 50 GW em capacidade instalada têm sido implementados anualmente desde 2014 (GWEC, 2018). China, Estados Unidos e Alemanha são os três países com maior capacidade instalada, já o Brasil subiu para oitava posição ao final do ano de 2017. O Brasil possui aproximadamente 15,3 GW em capacidade instalada (ANEEL, 2019). Estima-se que ao final de 2023 a capacidade instalada será de pelo menos 19,39 GW, visto que há contratos firmados para a construção de novos empreendimentos até esse ano. Cada vez mais o percentual de energia eólica aumenta na matriz energética brasileira, já tendo alcançado 9,1%, conferindo-lhe a terceira posição dentre as fontes de energia primária. O Plano Decenal de Expansão de Energia 2027 prevê que o potencial eólico seja aproveitado de forma contínua e em conjunto com a perspectiva de demanda energética da indústria nacional (MME; EPE, 2018). A geração eólica vem batendo recordes no Brasil, como ocorreu em 13/09/2019, quando respondeu por 74,12% da carga de energia elétrica do Nordeste, região que responde por cerca de 85,80% da capacidade instalada em energia eólica no Brasil enquanto, no Sul, esta é de 14,01%.

O avanço da participação em nossa matriz energética gera maior atenção para integração da energia eólica ao Sistema Interligado Nacional (SIN). Isso se deve ao fato de os ventos serem intermitentes. Nesse cenário, a previsão de geração eólica se torna importante, por isso o Operador Nacional do Sistema (ONS) desenvolveu modelos de previsão de geração para as

regiões Nordeste e Sul com o objetivo de auxiliar no planejamento da operação do sistema (NASCIMENTO et al., 2018). Além disso, o ONS obriga os agentes geradores a fornecerem previsões de geração para cinco dias à frente com resolução temporal de 30 minutos de acordo com o Submódulo 8.1 (ONS, 2016). A previsão de geração também permite o planejamento da Operação e Manutenção (O&M) do parque eólico, possibilitando maximizar os ganhos com manutenções em momentos em que a geração seria baixa.

Um fator importante na escolha das ferramentas necessárias para realizar a previsão é a definição do período à frente em que se deseja a informação, também chamado de horizonte de previsão. Não há consenso com relação à classificação de horizontes, porém Chang (2014) considera: curtíssimo prazo, de alguns minutos até uma hora à frente; curto prazo, de uma hora até algumas horas à frente; médio prazo, de algumas horas até uma semana à frente; e longo prazo, de uma semana até um ano ou mais à frente. As previsões de curtíssimo e curto prazo podem ser realizadas com dados de SCADA (Sistema de Supervisão e Aquisição de Dados) e ferramentas estatísticas, enquanto a previsão de médio prazo precisa do auxílio de modelos de previsão numérica do tempo (*Numerical Weather Prediction – NWP*). Segundo Foley et al. (2012), as previsões de médio prazo (de três a sete dias) são necessárias para planejar a manutenção de parques eólicos, o uso das fontes de energia para atender a demanda e agendar manutenção da rede e armazenamento de energia. Além disso, Wang, Guo e Huang (2011) comentam que previsões com horizonte de múltiplos dias à frente auxiliam no gerenciamento da operação e otimização do custo de operação.

Os estudos encontrados na literatura utilizam a geração inteira do parque no treinamento da rede neural artificial (RNA). Essa abordagem não consegue perceber quando alguns aerogeradores estão fora de funcionamento, seja a parada resultante de uma manutenção preventiva, corretiva ou ainda por uma limitação nos transformadores que permita apenas que alguns dos aerogeradores funcionem. Em busca de uma melhor abordagem de previsão para aplicação real pelos agentes geradores, houve a proposta do aerogerador equivalente médio, que é a média dos aerogeradores em funcionamento no parque após passarem pelo filtro de eliminação de valores atípicos (*outliers*) e pontos de manutenção. A RNA é treinada com os dados do aerogerador equivalente médio e a previsão de geração total do parque é obtida multiplicando o resultado dessa RNA pelo número de aerogeradores em funcionamento. Farias et al. (2019), verificou que o conceito de aerogerador equivalente possibilitou menores erros de previsão no resultado final da geração do parque, quando comparados aos valores obtidos por RNAs que previam diretamente a geração total.

No presente trabalho, busca-se desenvolver um procedimento visando à previsão de geração eólica para 144 horas (seis dias) com resolução temporal de 10 minutos, o que se enquadra em um horizonte de médio prazo, aplicado a dois parques eólicos de propriedade da empresa Atlantic Energias Renováveis S.A. O parque Ventos do Sertão (SER), situado no Complexo Eólico de Morrinhos (CEMOR) em Campo Formoso (BA), e o parque Aura Mirim II (MIR-2), no Complexo Eólico Santa Vitória do Palmar (CESVP) em Santa Vitória do Palmar (RS). Os parques considerados estão localizados no Nordeste e no Sul. Os esquemas de previsão de geração testados envolveram o uso de múltiplos modelos de previsão numérica do tempo, também conhecidos como *Numerical Weather Prediction* (NWP), tais como *Global Forecast System* (GFS), *Global Deterministic Prediction System* (GDPS) e *Weather Research and Forecasting* (WRF), em conjunto com aprendizado de máquina (*machine learning*). O desempenho destes procedimentos de previsão de geração será comparado com os resultados da previsão de geração obtida por meio da curva de potência dos aerogeradores e a velocidade do vento prevista pelo WRF, na altura do cubo do aerogerador. O período de estudo é de 23/12/2017 até 09/05/2018. Os principais pontos deste trabalho são a utilização de diferentes modelos NWP simultaneamente (multi-modelos), seleção das variáveis mais importantes, implementação do conceito de aerogerador equivalente médio e aplicação de redes neurais profundas (*deep neural networks* – DNN) para dois parques eólicos com características diferentes e em regiões distintas do Brasil. Uma contribuição importante será o horizonte de previsão de 144 horas em médias de 10 minutos, visto que a maior parte dos trabalhos presentes na literatura para o médio prazo desenvolvem modelos de previsão de geração com o horizonte de 72 horas.

## 1.2 OBJETIVOS

Este trabalho tem por objetivo principal:

- Obter a melhor metodologia de previsão de geração eólica para o horizonte de 144h em médias de 10 minutos para os parques Ventos do Sertão (SER) no Complexo Eólico de Morrinhos (BA) e Aura Mirim 2 (MIR-2) no Complexo Eólico de Santa Vitória do Palmar (RS).

O objetivo principal se desdobra nos seguintes objetivos específicos:

- Investigar o uso de diferentes modelos de previsão numérica do tempo na previsão de geração eólica;
- Investigar o uso de diferentes variáveis de entrada para as redes neurais artificiais;
- Verificar a efetividade de um método de seleção de variáveis;
- Implementar diferentes topologias de redes neurais artificiais superficiais e profundas na previsão de velocidade do vento na altura do cubo e geração do aerogerador equivalente médio;
- Comparar a previsão de geração do parque originada pela velocidade na altura do cubo e pela geração do aerogerador médio provenientes das melhores topologias de RNA com a previsão obtida com auxílio da curva de potência e a velocidade obtida pelo melhor modelo NWP na altura do cubo ou no nível mais próximo da mesma.

### 1.3 ESTRUTURA DO TRABALHO

O Capítulo 2 engloba uma revisão bibliográfica sobre modelos de previsão numérica do tempo e o estado da arte em previsão de geração de energia eólica. O Capítulo 3 descreve a metodologia adotada na execução do trabalho, citando as diferentes topologias de RNA, a definição do aerogerador equivalente, os métodos para obtenção da geração total do parque e as métricas de comparação entre os modelos. O Capítulo 4 apresenta e discute os resultados obtidos na comparação das diferentes propostas de previsão da geração eólica dos parques. E por fim no Capítulo 5 são apresentadas as conclusões e recomendações para os próximos trabalhos.

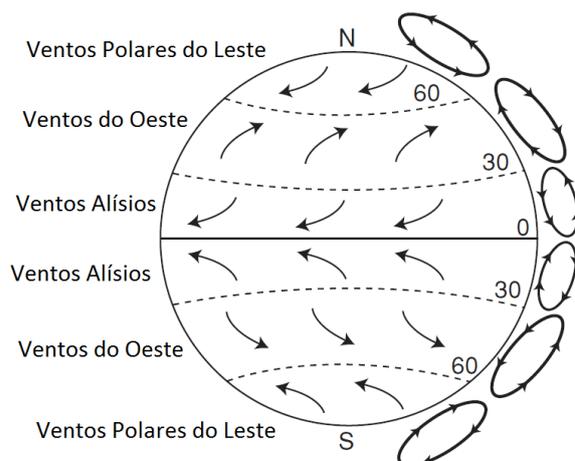
## 2 REVISÃO BIBLIOGRÁFICA

Os conceitos fundamentais que suportam o desenvolvimento do presente trabalho encontram-se neste capítulo. Há uma rápida explicação sobre energia eólica, diferentes abordagens de previsão de geração eólica, modelos de previsão numérica do tempo, inteligência artificial e mais detalhes relativos à sua aplicação na previsão de geração de energia.

### 2.1 ENERGIA EÓLICA

Os ventos resultam da movimentação de ar causada pela diferença de pressão e temperatura entre pontos da superfície terrestre. As massas de ar tendem a se mover em direção a zonas de baixa pressão e para longe de zonas de alta pressão. Essas diferenças de pressão ocorrem em razão do aquecimento desigual da superfície terrestre pela irradiância solar, ou seja, o sol é responsável pela energia presente dos ventos. No entanto, não se pode desprezar a rotação da Terra, visto que o efeito Coriolis afeta a movimentação das massas de ar no planeta, não permitindo que o vento sopre diretamente em direção às zonas de baixa pressão. O gradiente de temperatura entre os polos e a Linha do Equador, em conjunto com o efeito Coriolis, são responsáveis pelos ventos alísios (*trade winds*) e ventos do oeste (*westerly winds*). A Figura 1 mostra as correntes de ar a nível global.

Figura 1 - Padrão global de circulação dos ventos.



Fonte: Adaptado de JAIN (2011).

Além dos padrões globais há muitos padrões regionais de circulação de vento, tais como os que ocorrem entre a terra e o oceano, visto que a superfície terrestre se aquece e resfria mais rapidamente que o oceano. Podemos citar como resultado disso a brisa marítima e a brisa terrestre. A brisa marítima ocorre durante o dia quando a superfície terrestre local está mais quente do que a superfície marítima, pois o ar sobre a terra, menos denso, sobe devido à diminuição de pressão e o ar mais denso sobre o oceano é empurrado na direção terrestre. Durante a noite a diferença de temperatura se inverte resultando na brisa terrestre. Outros padrões regionais são as circulações em regiões montanhosas, que ocorrem durante o ciclo diurno em razão do resfriamento e aquecimento das encostas das montanhas (STULL, 1988). A circulação montanha-vale ocorre durante a noite quando a encosta da montanha se resfria mais por radiação do que o vale, o que faz com que o ar desça em direção aos vales; já a circulação vale-montanha ocorre durante o dia, quando as montanhas são aquecidas mais rapidamente que os vales, gerando uma corrente de vento ascendente (FOKEN, 2008).

Como explicado, os ventos são criados por diferença de temperatura e pressão, contudo, sua intensidade pode ser fortemente influenciada pela topografia e condições da superfície (HAU, 2006). Segundo Manwell, McGowan e Rogers (2009), condições de fluxo em terrenos montanhosos são complexas, por causa das elevações e depressões que ocorrem de maneira randômica. Isso remete à classificação dos terrenos em simples e complexos, onde simples significa um terreno com pequenas irregularidades e complexo um terreno em que a forma do terreno tem efeito significativo sobre o fluxo de ar na área considerada. Vale ressaltar que movimentações na atmosfera variam no tempo (de segundos a meses) e espaço (de centímetros a quilômetros) (MANWELL; MCGOWAN; ROGERS, 2009).

A potência  $P_w$ , em watts (W), presente no vento pode ser expressa pela equação 1:

$$P_w = \frac{1}{2} \rho A U^3, \quad (1)$$

onde,  $\rho$ ,  $A$  e  $U$  representam a massa específica, em  $\text{kg/m}^3$ , a área varrida pelo rotor, em  $\text{m}^2$ , e a velocidade do vento, em  $\text{m/s}$ , respectivamente. A dependência do cubo da velocidade do vento faz com que, por exemplo, um aumento de 10 % acarreta um aumento da potência disponível de 33 %.

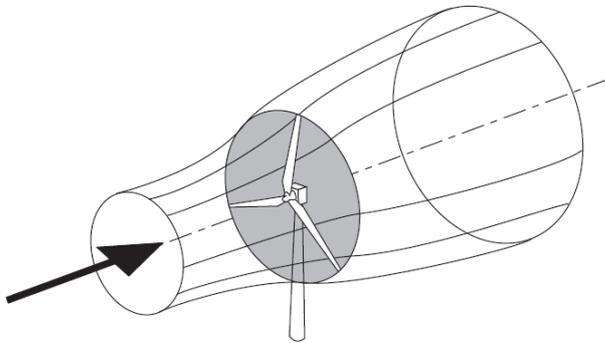
A velocidade do vento varia conforme a altura, devido ao gradiente de velocidade decorrente do efeito da viscosidade do ar, na camada limite atmosférica, e depende da rugosidade da superfície terrestre ou do terreno local. A tensão de cisalhamento na direção do escoamento,

na camada limite, é o produto da viscosidade pelo gradiente de velocidade na direção perpendicular à superfície terrestre. A partir de uma determinada altura, o efeito da superfície, torna-se desprezível e o gradiente da velocidade é nulo, a velocidade do vento torna-se uniforme.

As turbinas eólicas podem ser classificadas, quanto ao eixo, em horizontais e verticais. No mercado atual, a preferência é pelas turbinas de eixo horizontal (BURTON et al., 2011). Desta forma, os aerogeradores de eixo horizontal (turbina eólica e gerador elétrico) são os que têm apresentado o maior desenvolvimento tecnológico.

Ao passar pela turbina eólica o vento perde velocidade, pois o aerogerador extrai parte da energia cinética do vento. Assumindo que a massa de ar afetada pela turbina não se mistura com a que não passa pela turbina do aerogerador, e considerando a massa de ar um meio contínuo, ocorre uma expansão da área de passagem do escoamento de ar, desde a região anterior à turbina do aerogerador e após esta, como mostrado no esquema da Figura 2. A máxima porcentagem da energia que uma turbina eólica ideal pode extrair do vento é de 59,3 % (JAIN, 2011). Esse limite de coeficiente de potência para turbinas eólicas é conhecido como limite ou rendimento de Betz.

Figura 2 - Volume de controle que representa o escoamento de ar sobre uma turbina eólica.



Fonte: Burton et al. (2011).

## 2.2 MODELOS DE PREVISÃO NUMÉRICA DO TEMPO

Modelos de previsão numérica do tempo, conhecidos como *Numerical Weather Prediction* (NWP), em inglês, consistem de equações gerais da mecânica dos fluidos que descrevem o comportamento da atmosfera. Por serem não-lineares e não permitirem solução analítica, são utilizadas técnicas de solução numérica desse conjunto de equações, em função do tempo,

que permitem calcular os parâmetros característicos da atmosfera (pressão, velocidade e direção do vento, umidade, temperatura, entre outros) partindo de valores iniciais que são conhecidos de observações meteorológicas (COIFFIER, 2011). Há fortes evidências que a atmosfera é um sistema caótico para se prever, pois sua previsão é sensível às condições iniciais e os erros aumentam conforme o tempo avança no modelo (LYNCH, 2006).

A variedade de escalas temporais e espaciais simuladas por modelos contemporâneos de NWP é enorme. Previsões determinísticas do tempo, que servem para identificar eventos meteorológicos específicos, se estendem por semanas, enquanto previsões intersazonais das tendências do tempo são produzidas com acoplamento de modelos atmosféricos e oceânicos. As escalas espaciais resolvidas estão ficando cada vez menores. Alguns modelos que cobrem o globo têm resolução horizontal suficiente para simular processos de mesoescala (WARNER, 2011).

O meio contínuo da atmosfera é representado nos modelos numéricos em resoluções finitas que são os pontos de grade. Existem certos fenômenos físicos e dinâmicos que possuem escala espacial menor que a resolução do modelo numérico, por isso não conseguem ser representados. Entretanto, existem processos físicos e de escalas de movimento que, independentemente de sua resolução espacial, não podem ser representados pelos modelos numéricos. Para retratar esses processos físicos que não podem ser resolvidos diretamente pelos modelos numéricos existem as parametrizações. A transferência de radiação térmica pela atmosfera e a formação de nuvens são exemplos de fenômenos que precisam ser parametrizados. Esquemas de parametrização conseguem representar os aspectos essenciais do processo físico, pois existem simplificações e idealizações de processos físicos complexos (STENSRUD, 2007).

Modelos de previsão global têm por objetivo representar os eventos atmosféricos ao redor do globo inteiro. Dentre os modelos globais pode-se citar o *Global Forecast System* (GFS) desenvolvido pelo *National Center for Environmental Prediction* (NCEP), o *High Resolution Model* (HRES) desenvolvido pelo *European Centre for Medium-Range Weather Forecast* (ECMWF) e o *Global Deterministic Forecast System* (GDPS) desenvolvido pelo *Canadian Meteorological Centre* (CMC).

Modelos de previsão de mesoescala são modelos que abrangem uma área limitada, pois objetivam representar os processos meteorológicos de mesoescala. Esses processos ocorrem sobre distâncias que vão de 2 até 2000 km, tais como tempestades (JACOBSON, 2005). Segundo Prusov e Doroshenko (2018), dependendo do território em que o modelo é implementado ele pode ser classificado em local (entre 2 e 200 km) e regional (entre 200 e 2000 km).

Ressalta-se que modelos atmosféricos de mesoescala podem levar em consideração as características do terreno (topografia local), isso ocorre conforme a escala espacial do fenômeno atmosférico de interesse. As condições de contorno laterais para um modelo NWP de área limitada vêm de modelos globais que são rodados previamente. Essa dependência pode causar problemas, pois sem o resultado do modelo global não há como executar o modelo de mesoescala (WARNER, 2011). Exemplos de modelos de mesoescala são o Modelo Eta *Brazilian Developments on the Regional Atmospheric Modelling System* (BRAMS) e *Weather Research and Forecasting* (WRF). A redução da resolução espacial, por meio de domínios aninhados, e temporal realizada pelos modelos de previsão de mesoescala é conhecida como processo de *downscaling* dinâmico (PIELKE, 2002).

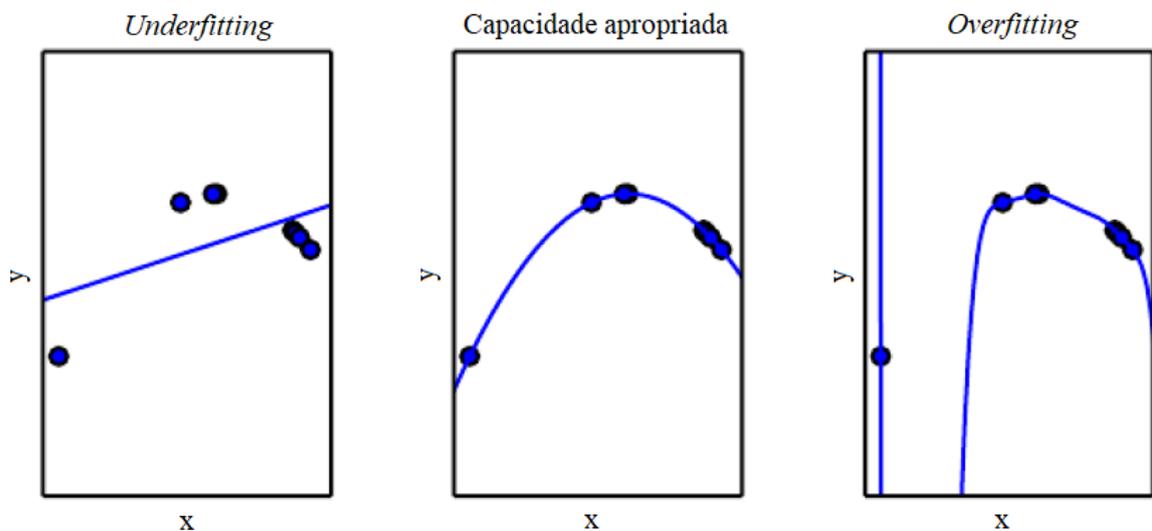
### 2.3 MACHINE LEARNING

Inteligência artificial (IA) é um dos campos mais novos da ciência e engenharia, tendo sido essa nomenclatura adotada em 1956, na Primeira Conferência de Inteligência Artificial organizada pela IBM. IA é um campo universal de estudos, com diversas aplicações que vão desde o jogo de xadrez, do escrever poesias, ou compor músicas até dirigir carros. Esse campo tenta não apenas entender, mas também construir entidades inteligentes (RUSSEL; NORVIG, 2010). Dentro do campo da IA existe um ramo chamado de aprendizado de máquina, conhecido como *machine learning*, em que dados são reunidos como fazem os sentidos humanos e processados por métodos de *machine learning* para conduzir predições e tomar decisões no mesmo nível que um humano.

Segundo Mohammed; Khan; Bashier (2017), o termo *machine learning* significa capacitar as máquinas a aprender a partir de dados sem a necessidade de programá-las explicitamente. Alguns dos modelos mais comuns de *machine learning* são redes neurais artificiais (RNA), máquinas de vetores de suporte (*support vector machines* - SVM) e redes bayesianas (HEATON, 2013). Sergio e Ludemir (2015) comentam em seu trabalho que dentro do ramo de *machine learning* surgiu uma nova área de estudo chamada *deep learning*, quando Hinton, Osindero e Teh (2006) conseguiram pela primeira vez treinar redes neurais artificiais profundas, as quais são classificadas como redes neurais com duas ou mais camadas escondidas, obtendo melhores resultados do que redes neurais superficiais (apenas uma camada escondida).

Géron (2017), em seu livro, comenta que os principais desafios do *machine learning* são o *underfitting* e *overfitting*. Sendo que *overfitting* é quando o modelo tem uma boa performance com os dados treinados, porém não generaliza bem, falhando quando testado com dados fora do banco de dados de treinamento. Já *underfitting* é o oposto, ocorre quando o modelo é muito simples para aprender os padrões escondidos nos dados analisados. A Figura 3 busca exemplificar esses conceitos, pois no caso mostrado, à esquerda, uma função linear não captaria a real estrutura dos dados e geraria *underfitting*, visto que o modelo com capacidade apropriada, que representa corretamente, é uma função quadrática, figura do meio. Na figura da direita, temos o exemplo de *overfitting*, onde uma função de nono grau passa exatamente sobre os pontos do banco de dados de treinamento, porém há um vale profundo entre os pontos, o que não existe na função real que define esses pontos.

Figura 3 - Exemplo de underfitting, capacidade apropriada e overfitting em um conjunto de dados de treinamento gerado sinteticamente.



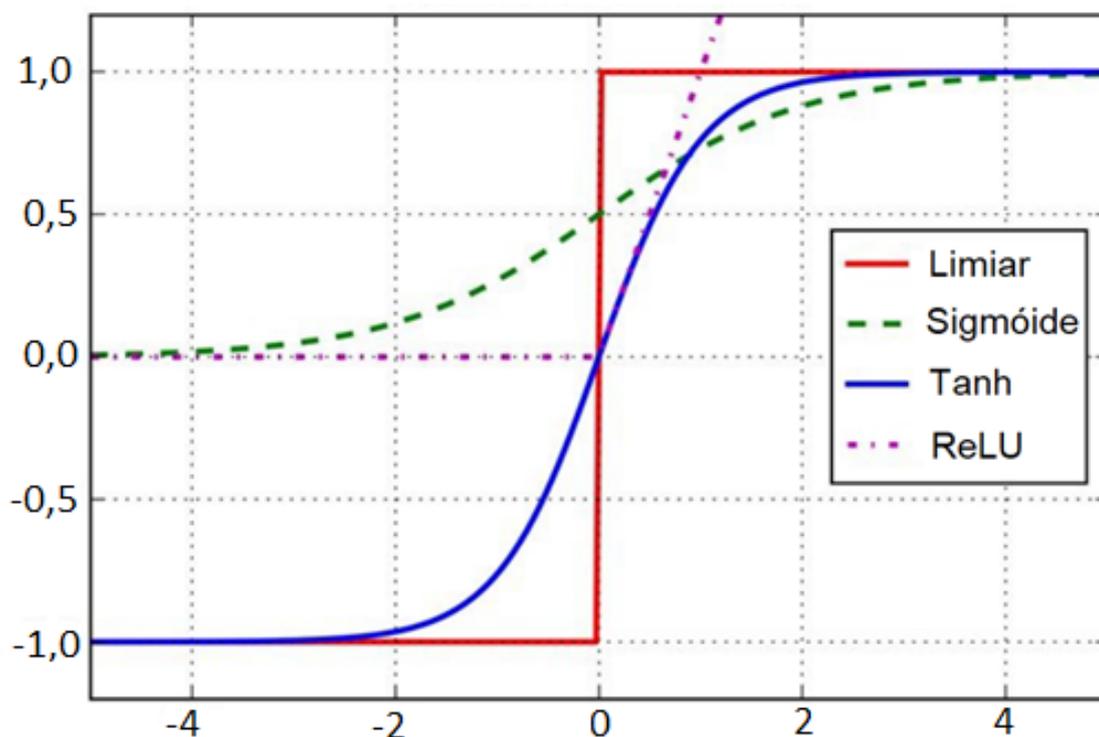
Fonte: Adaptado de (GOODFELLOW; BENGIO; COURVILLE, 2016).

### 2.3.1 Redes neurais artificiais

Redes neurais artificiais representam uma pequena parte do campo de inteligência artificial (HEATON, 2015). A inspiração das redes neurais vem das redes neurais biológicas, que consiste no sistema nervoso central em um cérebro animal (MOHAMMED; KHAN; BASHIER, 2017). Basicamente RNAs compreendem neurônios, camadas e funções de ativação. Os neurônios em uma RNA podem ser de entrada, escondido ou de saída. Neurônios de

entrada passam informação para dentro da rede neural e neurônios de saída retiram as informações da rede neural. Já os neurônios escondidos ocorrem no meio desses neurônios e ajudam a processar a informação. As funções de ativação ou funções de transferência são responsáveis por estabelecer conexão para a saída dos neurônios, sendo mais comuns a função sigmoide e a função tangente hiperbólica ( $\tanh$ ), porém existem mais funções, tais como a função limiar ( $step$ ) e a função *Rectified Linear Unit* (ReLU). Alguns exemplos de função de ativação podem ser vistos na Figura 4. Segundo Heaton (2015), ReLU se tornou uma ferramenta importante para o *deep learning* e a função de ativação padrão das camadas escondidas de redes neurais profundas, conceito também compartilhado por Chollet (2017). A razão para isto é que diferentemente da função sigmoide e tangente hiperbólica, a função ReLU não é suscetível ao problema da dissipação do gradiente (*vanishing gradient problem*) durante o treinamento, pois sua derivada é zero ou um. A solução de problemas não-lineares por meio de redes neurais é permitida pelas conexões não lineares entre os neurônios.

Figura 4 - Exemplos de funções de ativação para os neurônios das camadas escondidas.

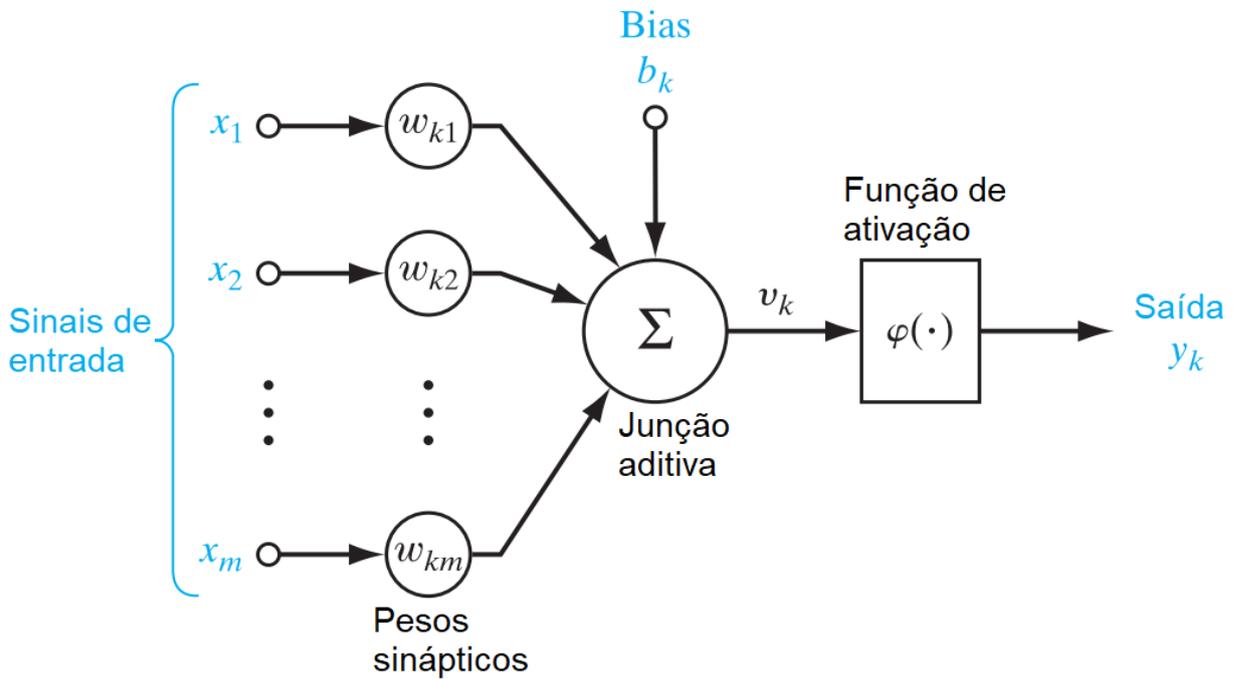


Fonte: Adaptado de (GÉRON, 2017).

As informações fluindo apenas no caminho da camada de entrada para a camada de saída caracteriza uma rede neural com alimentação adiante, também conhecida como *feedforward neural network*; já se houver algum laço de realimentação (*feedback*), onde o sinal de saída de um neurônio volta para a entrada do mesmo ou de outros neurônios, a rede é considerada recorrente. Segundo analogia de Hayking (2009), o processo de aprendizagem de uma rede neural artificial pode ocorrer com ou sem professor. O processo de aprendizagem com um professor ocorre quando os dados são rotulados, o que caracteriza um treinamento supervisionado. Por outro lado, a ausência do professor significa a inexistência de rótulos para os dados, que pode ocorrer pela aprendizagem por reforço (*reinforcement learning*), onde o aprendizado ocorre com interação contínua com o ambiente; e aprendizagem não-supervisionada, na qual há uma medida independente da qualidade da tarefa. Os neurônios de cada camada de uma RNA podem ser totalmente conectados ou não com as camadas adiante. Uma rede com todos os neurônios se conectando entre si é chamada de *fully connected* ou densa.

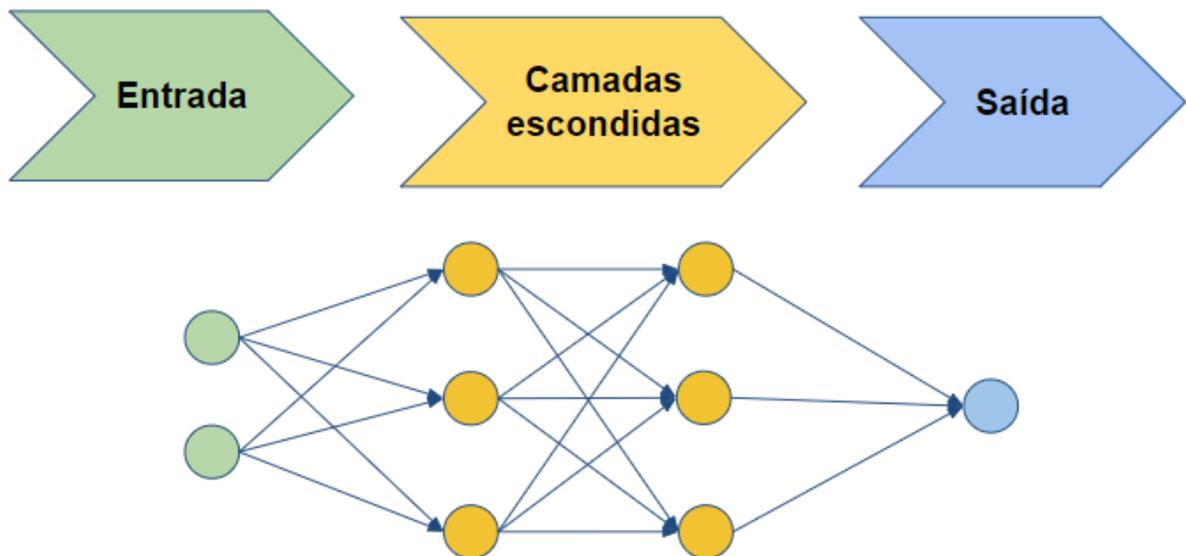
Para entender bem o conceito de redes neurais é importante conhecer a representação do modelo matemático de um neurônio artificial, que é a unidade básica para a operação da RNA. A representação do modelo matemático de um neurônio artificial pode ser vista na Figura 5. Esse recebe informações de uma ou mais fontes que podem ser de outros neurônios ou de dados que alimentam a rede neural. O neurônio artificial multiplica as entradas pelos pesos sinápticos, após isso há a soma desses produtos e do *bias* também conhecido como viés (termo com valor constante) do neurônio. O resultado dessa soma é processado pela função de ativação. Caso o resultado dessa função ultrapasse o limite (*threshold*), o mesmo é ativado (RUSSEL; NORVIG, 2010). Os neurônios em conjunto formam camadas que processam as informações. Hayking (2009) considera uma rede com uma ou mais camadas escondidas como uma rede neural multicamada perceptron (*Multilayer Perceptron - MLP*), com a condição que as funções de ativação dos neurônios sejam não-lineares, existam camadas escondidas e haja um alto grau de conectividade entre os neurônios. A Figura 6 mostra o exemplo de uma MLP, que é uma rede alimentada adiante. Ela recebe os estímulos na camada de entrada, os quais são processados pelos neurônios das camadas escondidas e resultam em uma resposta na camada de saída.

Figura 5 - Modelo matemático de um neurônio artificial.



Fonte: Adaptado de (HAYKIN, 2009).

Figura 6 - Esquema de uma rede neural multicamadas perceptron (*Multilayer Perceptron* –MLP), que é uma rede neural alimentada adiante (*feedforward neural network*) densa, onde as setas indicam o sentido da informação.



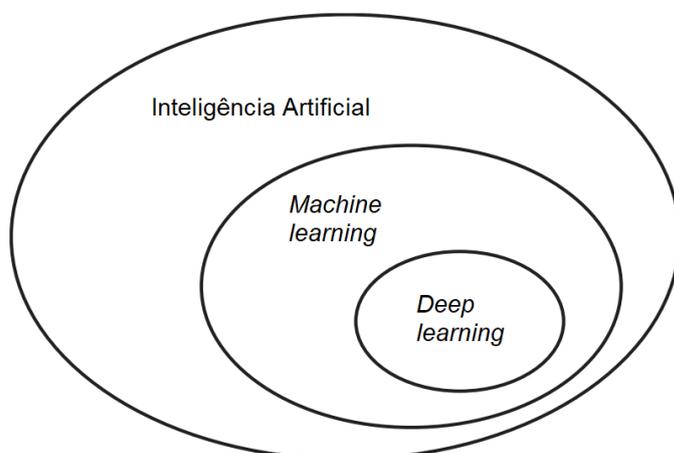
Os pesos sinápticos da rede neural são continuamente alterados e atualizados durante a fase de treinamento para que se consiga atingir a acurácia e generalização desejada. O método

de retropropagação do erro (*backpropagation*) é o mais comum para o treinamento de redes neurais (HEATON, 2015). O ajuste dos pesos sinápticos durante o treinamento ocorre por meio do otimizador que implementa o algoritmo de retropropagação do erro. Alguns exemplos de otimizadores são o Adam, Adagrad, RMSProp, Gradiente Descendente Estocástico (*Stochastic Gradient Descent – SGD*), entre outros. O treinamento com o algoritmo de *backpropagation* consiste em dois passos: no primeiro passo há a propagação da informação da entrada para a saída, nesta etapa os pesos são fixos; no segundo passo existe a retropropagação do erro, este obtido por meio função de perda (*loss function*), que ocorre através da regra da cadeia. Há a alteração dos pesos sinápticos no passo de retropropagação do erro com o objetivo de minimizar a função perda. A repetição desses dois passos por um número suficiente de vezes resulta em uma rede neural treinada (CHOLLET, 2018).

### 2.3.2 Deep learning

Segundo Heaton (2015), *deep learning* representa as ferramentas ou o caminho para treinar redes neurais profundas, as quais são qualquer rede neural com duas ou mais camadas escondidas. Para Goodfellow, Bengio e Courville (2016), redes MLP com duas ou mais camadas são exemplos de modelos de *deep learning*. Como já comentado anteriormente e reforçado pelo diagrama de Venn na Figura 7, *deep learning* é uma área dentro de *machine learning*, o qual por sua vez é um dos campos mais novos da IA. O aprendizado de modelos computacionais, compostos por múltiplas camadas de processamento, da representação de dados com múltiplos níveis de abstração é permitido pelo *deep learning* (LECUN; BENGIO; HINTON, 2015).

Figura 7 - Diagrama de Venn com as relações entre *deep learning*, *machine learning* e inteligência artificial.



Fonte: Adaptado de (CHOLLET, 2018).

## 2.4 MODELOS DE PREVISÃO DE GERAÇÃO EÓLICA

Modelos de previsão de geração eólica visam a prever a potência média a ser gerada por um parque eólico durante um determinado período de tempo. O horizonte de tempo  $T$ , para o qual as previsões são feitas, representa a duração do período de previsão. A resolução temporal da previsão é representada pelo passo de tempo (*time step*, em inglês), sendo que o tamanho deste depende do horizonte (LYDIA; SURESH KUMAR, 2010).

O horizonte de uma previsão é uma importante característica, pois indica o período de tempo futuro em que a geração de energia será prevista. Pode-se classificar os horizontes de previsão em: curtíssimo prazo (*very short term*, em inglês), com um alcance de poucas horas, porém não há consenso quanto ao número de horas, Usaola et al. (2004) propôs um limite de 4 horas, já Möhrlen (2004) um limite de 9 horas; curto prazo (*short term*, em inglês), horizonte de previsão que vai do limite da previsão de muito curto prazo até 48 ou 72 horas; médio prazo (*medium term*, em inglês), que vai do limite da previsão de curto prazo até o limite de sete dias, sendo este horizonte de tempo possível só com o uso de modelos de previsão numérica do tempo de grandes centros, tais como o ECMWF e GFS (MONTEIRO et al., 2009); e longo prazo (*long term*, em inglês) de uma semana até um ano ou mais (CHANG, 2014). Giebel et al. (2011) ressaltam que modelos de previsão de geração que envolvem previsões meteorológicas têm seu horizonte de tempo determinado pelo modelo NWP. Segundo Giebel e Kariniotakis (2017), um dos maiores desafios da previsão de geração eólica é a sua dependência da volatilidade do vento, a qual influencia em todas as escalas de tempo de previsão. Dependendo da aplicação, há uma escolha de horizonte de previsão. Por exemplo, previsões de médio prazo são interessantes para o planejamento de manutenção de aerogeradores, de linhas de transmissão, ou de grades componentes de plantas geradoras (GIEBEL; KARINIOTAKIS, 2017). Um fato importante é que quanto mais a frente se olha em um modelo de previsão do tempo, menor é a acurácia, a qual decresce fortemente entre o quinto e o sétimo dia de previsão (MORENO et al., 2003).

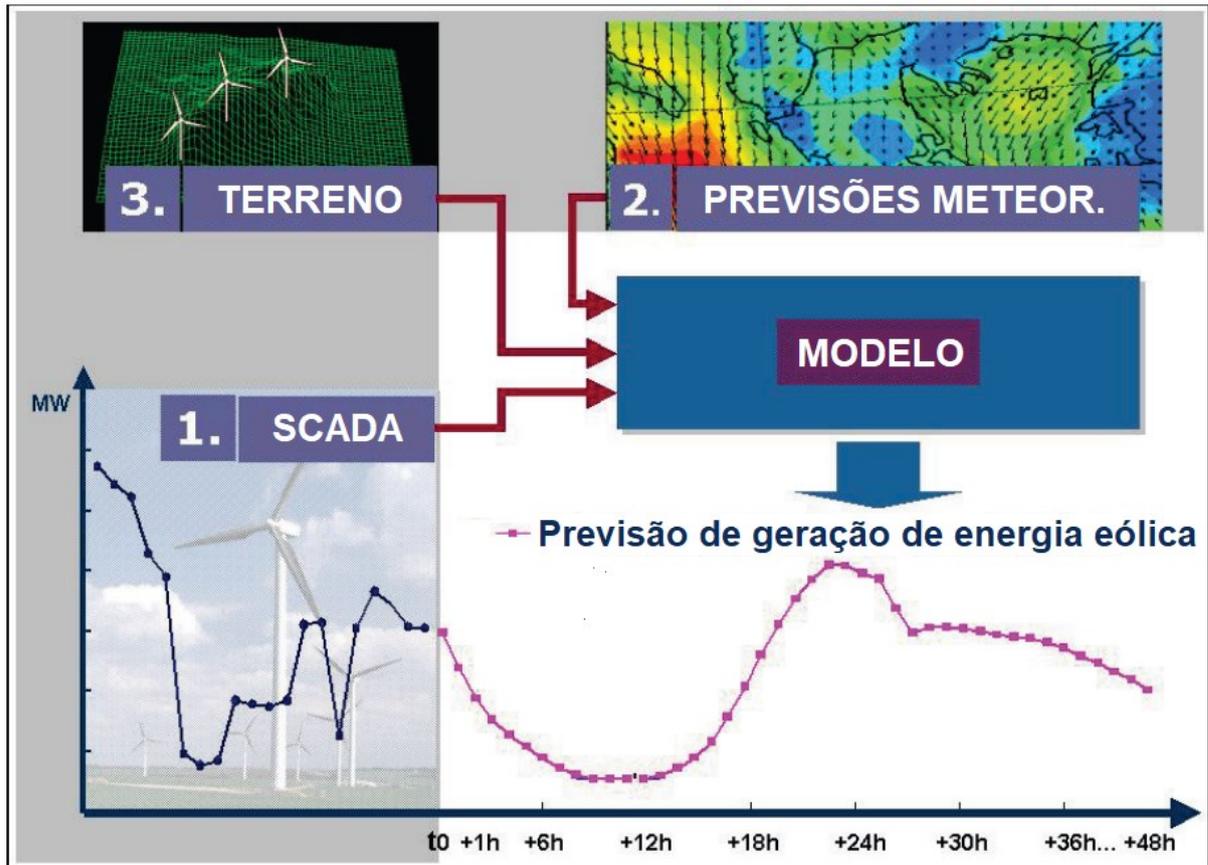
Os dados necessários para a realização da previsão de geração eólica podem variar conforme o horizonte de tempo escolhido. Alguns dados necessários segundo Lydia e Suresh

Kumar (2010) são: velocidade do vento, direção do vento, densidade do ar, diferença de temperatura, fluxo de calor sensível na superfície e porcentagem da superfície coberta por vegetação. Já Monteiro et al. (2009) cita como dados de entrada necessários para a realização de previsões de geração no nível de parques eólicos: velocidade e direção do vento, temperatura, pressão, umidade, disponibilidade das turbinas. Conforme Lydia e Suresh Kumar (2010), previsões de geração eólica dependem pouco da previsão de densidade do ar e bastante da previsão da velocidade e direção do vento entre 50 e 100 m de altura em relação ao solo.

Diferentes abordagens de previsão de geração eólica foram desenvolvidas, porém é difícil dizer qual é a melhor, visto que o desempenho do modelo depende significativamente das características do parque eólico. Por isso, um modelo de previsão pode ter uma boa performance em um sítio (*site*), entretanto, isso não garante que o modelo tenha um bom funcionamento em outro local (JUNG; BROADWATER, 2014). Giebel e Kariniotakis (2017) comentam que programas de previsão de geração eólica não são “*plug-and-play*”, pois sempre são dependentes do local onde são aplicados (*site-dependent*).

Os modelos de previsão de geração eólica podem ser classificados em três grupos principais: modelos físicos, modelos estatísticos e modelos combinados, capazes de combinar as características dos dois primeiros. Segundo Giebel et al. (2011) essa classificação ocorre conforme os dados de entrada. Observando a Figura 8: a utilização apenas dos dados (1) SCADA (indicando dados em tempo real) como dados de entrada caracteriza uma abordagem estatística que serve para um horizonte de curtíssimo prazo; já a utilização de (2) previsões meteorológicas podem indicar uma abordagem física ou uma abordagem estatística; o emprego de (2) previsões meteorológicas e de (3) características do terreno indicam uma abordagem física; o uso de dados (1) SCADA e de (2) previsões meteorológicas como dados de entrada designam uma abordagem estatística com modelo de previsão do tempo; e, por fim, a utilização de (1), (2) e (3) qualificam como uma abordagem combinada (GIEBEL et al., 2011).

Figura 8 - Figura de auxílio para explicar as diferentes abordagens de previsão.



Fonte: Adaptado de (GIEBEL et al., 2011).

A abordagem física consiste de um grupo de modelos de diferentes processos físicos envolvidos (LYDIA; SURESH KUMAR, 2010). No método físico, ocorre o refinamento dos dados do modelo de previsão numérica do tempo (NWP) para levar em conta as condições do terreno por meio de um método de *downscaling* dinâmico (redução da escala), o qual é baseado na física da parte baixa da camada limite atmosférica. O método físico requer a descrição física detalhada das usinas eólicas e de seus arredores, incluindo: descrição do parque eólico (leiaute do parque e curva de potência das turbinas, etc) e descrição do terreno (oroografia, rugosidade, obstáculos, etc). Então, os dados de velocidade do vento refinados na altura do cubo (*hub*, em inglês) dos aerogeradores são utilizados na correspondente curva de potência para calcular a produção de energia pelo aerogerador (JUNG; BROADWATER, 2014).

Na abordagem estatística, uma vasta quantidade de dados é analisada e processos meteorológicos não são explicitamente representados. A ligação entre produção de geração histórica e clima é determinada e então usada para prever a futura saída de potência. Geralmente uma relação estatística é desenvolvida entre a previsão do tempo por um modelo NWP global e a potência de saída do parque eólico (FOLEY et al., 2012). Os métodos estatísticos envolvem tanto abordagens estatísticas clássicas como *Autoregressive model (AR)*, *Moving average model (MA)*, *Autoregressive Moving model (ARMA)* e *Autoregressive Integrated Moving Average model (ARIMA)*, quanto abordagens estatísticas de aprendizado (*learning approaches*). Segundo Foley et al. (2012), métodos de abordagem de aprendizado (*learning approach methods*) são comumente referidos como métodos de inteligência artificial (IA). O mérito principal dos modelos de previsão de geração eólica baseados em inteligência artificial é sua potencial habilidade na mineração de dados (*data-mining*) e extração de características (WANG; WANG; WEI, 2015). Dentre os métodos com abordagem de aprendizado pode-se destacar o uso de redes neurais artificiais (RNA) e máquinas de vetores suporte (*Support Vector Machines – SVM*) (FENG et al., 2017).

A abordagem de combinação tem como objetivo principal melhorar a performance, isso é realizado tomando as vantagens de cada modelo. Combinações podem consistir de abordagem física e estatística ou combinar diversos modelos estatísticos. A vantagem de combinar resultados de diferentes abordagens de modelamento é melhorar a acurácia da previsão. Além disso, a combinação de modelos reduz riscos durante eventos extremos, tal como uma tempestade, onde alguns tipos de modelo podem ter erros significativos (JUNG; BROADWATER, 2014).

#### **2.4.1 Fatores que influenciam a acurácia de modelos de previsão de geração eólica**

Conforme comentado anteriormente, é muito difícil dizer qual modelo de previsão de potência eólica é o melhor por causa de sua dependência em relação ao sítio. Jung e Broadwater (2014) pesquisaram na literatura para verificar como a acurácia geral das previsões varia em relação a alguns fatores independentes do tipo de modelo adotado. Eles constataram a influência dos seguintes fatores:

- *Horizonte de previsão*: a acurácia da previsão decresce quando o horizonte da previsão aumenta. Monteiro et al. (2009) comentam que tipicamente o NRMSE de uma previsão de geração de um parque eólico, normalizado sobre a capacidade instalada, fica em torno de 6 e 10 % para as seis primeiras horas e, posteriormente, aumenta para valores

entre 14 e 17 % para 48 horas. Já Giebel e Kariniotakis (2017) informam que o NRMSE varia, geralmente, entre 9 e 14 % para previsões com o horizonte de 24 horas. Para o mesmo horizonte de um dia à frente, o NRMSE de um parque na China a acurácia ficou entre 16 e 17 % (WANG; GUO; HUANG, 2011);

- *Complexidade do terreno*: Há um significativo aumento no valor médio do MAE normalizado (NMAE) quando a complexidade do terreno é aumentada (MARTI et al., 2006);
- *Variabilidade sazonal*: A performance de modelos de previsão é relacionada à variabilidade sazonal, em Lange e Focken (2005). Os erros de previsão são menores no inverno do que no verão, pois no verão há mais tempestades e sistemas de baixa pressão com zonas frontais de movimentação rápida;
- *Condição do tempo*: Estudo realizado por Pinson e Kariniotakis (2004) comparou o erro de previsão em função do índice de risco meteorológico (*Meteorological Risk Index* (MRI), em inglês), sendo o MRI uma avaliação da estabilidade do tempo. Constatou-se que o erro de previsão aumenta linearmente quando o MRI aumenta (alto MRI representa regimes de tempo instáveis). Lange e Heinemann publicaram artigos em 2002 e 2003, nos quais verificaram que o erro de previsão em situações de baixa pressão é maior do que em situações de alta pressão.

Monteiro et al. (2009) afirmam que a performance de um programa de previsão de geração eólica é fortemente relacionada a diversas características, algumas já citadas acima. Porém, eles também citam outros fatores que devem ser levados em consideração:

- *Tamanho do parque eólico*: leiaute do parque, potência instalada, número de aerogeradores;
- *Localização geográfica*: no mar (*offshore*), em terra (*onshore*), próximo à costa;
- *Qualidade do dado*: erro de previsão do modelo NWP, erro de medição no SCADA;
- *Tipo de modelo NWP*: modelo de mesoescala, modelo de microescala, resolução espacial;
- *Tipo de método de previsão*: físico, estatístico, combinado;
- *Condições climatológicas do local do parque*.

### 2.4.2 Melhorias na previsão de geração eólica

Jung e Broadwater (2014) discutem potenciais opções para melhorar a acurácia das previsões de geração eólica. Algumas das opções levantadas por eles e outras na literatura são:

- Combinação de diferentes modelos de previsão numérica do tempo. Essa combinação permite melhorar a previsão em relação ao uso de apenas um modelo NWP (ALESSANDRINI et al., 2011; CALI et al., 2008; VACCARO et al., 2011; VON BREMEN, 2007), assim como redução de risco de falha do modelo em eventos extremos;
- Combinação de diferentes métodos de previsão, por exemplo, diferentes arquiteturas de redes neurais artificiais ou diferentes algoritmos de *machine learning* (FENG et al., 2017; GIORGI; FICARELLA; TARANTINO, 2011);
- Seleção de parâmetros de entrada para o modelo de previsão é crucial para a performance das previsões. Além da importância óbvia da velocidade do vento como parâmetro de entrada, os dados de temperatura e pressão podem ajudar a melhorar a previsão (GIORGI; FICARELLA; TARANTINO, 2011; LANGE; HEINEMANN, 2003; SALCEDO-SANZ et al., 2018; TOOK et al., 2011).
- Transformar os dados de velocidade do vento por meio de algumas técnicas como *wavelet decomposition* (CATALÃO; POUSINHO; MENDES, 2011; LIU et al., 2010) e *empirical mode decomposition* (LIU et al., 2012; ZHANG et al., 2017). Essas transformações ajudam a lidar com os picos e flutuações dos dados brutos de vento (WANG et al., 2017).

### 2.5 MACHINE LEARNING APLICADO À PREVISÃO DE GERAÇÃO EÓLICA

Essa seção tem o objetivo de comentar alguns trabalhos relevantes de previsão de geração eólica desenvolvidos por meio da aplicação de *machine learning*. Vale destacar que a maioria dos estudos encontrados na literatura relativos a previsões de geração de energia eólica focam nos horizontes de previsão entre curtíssimo e curto prazo (entre minutos e no máximo 72 horas), o que deixa um vazio em estudos de revisão e análises focados no médio (de 72 horas à sete dias) e longo prazo (de uma semana a um ano) (VARGAS et al., 2019). Lembrando que o horizonte da presente dissertação é de seis dias (144 horas) adiante com resolução temporal de dez minutos.

Li et al. (2001) utilizaram redes neurais artificiais superficiais para prever a geração de aerogeradores de um parque nos Estados Unidos. Eles empregaram medições de duas torres como dados de entrada para a rede neural e compararam o desempenho com os resultados da curva de potência do fabricante, na qual foi utilizada a velocidade de uma das torres escolhida com base na direção do vento no momento. Os autores decidiram treinar uma rede neural para cada aerogerador, 12 redes ao total, isso com o objetivo de reduzir o tamanho e complexidade das RNAs e também para tirar a influência de aerogeradores desligados (*off-line*) enquanto outros estão em funcionamento, pois isto é algo que ocorre durante a operação do parque eólico.

Von Bremen (2007) empregou redes neurais artificiais para prever a geração até dois dias à frente de um parque eólico no mar (*offshore*) localizado a dois quilômetros ao Leste de Copenhague (capital da Dinamarca). As redes neurais utilizaram a velocidade do vento de modelos NWP. O estudo consiste em três esquemas: o primeiro com o modelo ECMWF; o segundo com o modelo HIRLAM do Instituto de Meteorologia da Dinamarca; e o terceiro com a combinação da velocidade destes dois modelos de previsão numérica do tempo. O resultado mostrou que a combinação dos modelos NWP, multi-modelo, beneficia a previsão de geração eólica. O NRMSE de 24 horas à frente do esquema que combina os dois modelos de NWP ficou 1 % menor que a previsão que utiliza apenas o ECMWF, o que é uma melhora relativa de aproximadamente 6 %. O valor de NRMSE para a previsão do terceiro esquema foi de 15,8 %.

Dois abordagens de modelos do tipo conjunto (*ensemble*, em inglês) foram estudadas por Cali et al. (2008) em seu artigo para previsão de geração eólica, 24 horas à frente, com resolução horária para dois parques, na Alemanha. A primeira trabalha com o uso de diferentes modelos NWP (multi-modelos NWP) e a segunda abordagem trabalha com múltiplos esquemas de previsão, nestes são utilizados resultados de um conjunto de previsões do tempo com 75 membros. Três modelos de previsão numérica do tempo foram utilizados, os quais são independentes, visto que utilizam diferentes modelos globais e locais. As redes neurais treinadas por eles possuíam três camadas escondidas e dois tipos de dados de entrada, um com os resultados dos modelos NWP e outro com a geração medida (SCADA). Segundo os autores, embora os modelos NWP sejam completamente independentes, eles mostraram erros de previsão de geração muito similares quando utilizados em redes neurais artificiais. Os valores de NRMSE ficaram em torno de 10,5 % da capacidade instalada.

Salcedo-Sanz et al. (2009) propuseram um método para aumentar a acurácia da previsão de velocidade do vento no curto prazo explorando a diversidade nas variáveis de entrada de redes neurais, a qual foi obtida pelo uso de diferentes modelos globais e diferentes parametrizações no modelo de mesoescala MM5. As redes neurais empregadas possuíam apenas uma camada escondida e eram do tipo *feedforward*. Os modelos globais de previsão numérica do tempo utilizados foram o GFS, NOGAPS (*Navy Operational Global Prediction System, USA Navy*) e previsão global do CMC (*Canadian Meteorological Center*). Eles mostraram que no horizonte de 48 horas, o resultado conjunto do banco de redes neurais, com todos os modelos de previsão do tempo obtidos pelo MM5, superou o resultado do melhor modelo NWP utilizado em uma rede neural.

Zhao et al. (2012) propuseram um esquema de previsão de geração eólica testado em um parque chinês. Esse esquema empregou redes neurais artificiais com variáveis de entrada provenientes da geração medida pelo SCADA e do modelo de mesoescala WRF com condições de contorno dadas pelo GFS. A rede neural era uma *feedforward* com uma camada escondida e 13 neurônios. A geração era prevista diretamente pela RNA com um horizonte de 24 horas e resolução temporal de 15 minutos. Eles também fizeram um teste com e sem filtro de Kalman sobre os dados de velocidade obtidos pelo modelo NWP antes desses alimentarem a rede neural, com filtro o NRMSE foi de 16,47 % e sem filtro foi de 17,81 % da capacidade instalada do parque. O sistema proposto foi considerado com uma boa performance de previsão de geração eólica.

Alessandrini, Sperati e Pinson (2013) compararam as previsões probabilísticas para um parque no Sul da Itália, com horizonte de 72 horas, obtidas por meio de redes neurais artificiais superficiais com dois modelos, separadamente, de *ensemble* (conjunto) de previsões, o ECMWF EPS (*Ensemble Prediction System in use at the European Centre for Medium-Range Weather Forecasts*) e o COSMO-LEPS (*Limited-area Ensemble Prediction System developed within COnsortium for Small-scale MOdelling*). Houve também a comparação de três previsões determinísticas, sendo duas obtidas da média da função de distribuição de probabilidade prevista pelo ECMWF EPS e COSMO-LEPS e uma obtida pela previsão determinística do ECMWF com redes neurais artificiais superficiais. Chegaram à conclusão que uma maior resolução do *ensemble* pode gerar um resultado ligeiramente melhor na previsão determinística, porém a previsão obtida com o uso do modelo determinístico do ECMWF se mostrou com uma

performance um pouco melhor em termos de RMSE. Quando comparados no RMSE com relação ao avanço do tempo de previsão, não é possível notar um aumento significativo no NRMSE, o qual fica entre 13 e 19%.

Com o intuito de verificar a contribuição da modelagem de mesoescala, Artipoli e Durante (2014) comparam três esquemas de previsão de geração eólica com o horizonte de 72 horas à frente, esses esquemas se utilizam de RNA e variáveis de entrada de diferentes modelos de previsão numérica do tempo. O primeiro esquema utiliza apenas dados do modelo global GFS, o segundo esquema emprega o resultado do modelo de mesoescala WRF e o terceiro esquema emprega dados provenientes da rodada do GFS e WRF. O modelo WRF tem suas condições de contorno laterais determinadas pela rodada do modelo GFS. Os modelos foram testados em quatro parques localizados em terrenos complexos no Sul da Itália e constatou-se que o sistema que empregou apenas os resultados do modelo de mesoescala de WRF foi superado em todos pelo terceiro esquema, o qual utiliza o GFS e WRF em conjunto. Entretanto, afirmam que o modelo de mesoescala é importante na previsão de geração eólica de terrenos complexos, pois adiciona informações locais que não estão presentes em modelos globais. Em seu trabalho comentam que em climas complexos a previsibilidade da geração eólica pode ser significativamente baixa. Os valores de NRMSE para o esquema três dos quatro parques foram 14,2 %, 18,1 %, 15,6 % e 12,4 %.

Sergio e Ludermir (2015) aplicaram *deep learning* para previsão da velocidade horária do vento no Nordeste brasileiro. Foram utilizados três tipos de algoritmo: *Deep Belief Networks* (DBN), *Stacked Denoising Autoencoder* (SDAE) e rede neural multicamadas perceptron (*Multilayer Perceptron* - MLP), esse último não possui pré-treinamento. As redes neurais testadas possuíam duas camadas escondidas, havendo variação no número de neurônios nas camadas com o intuito de descobrir uma previsão com menor erro. Os resultados do estudo não foram conclusivos quanto ao melhor algoritmo para cada banco de dados testado.

Feng et al. (2017) comentam que RNA e SVM são os modelos mais populares na previsão de geração eólica. O artigo trata do desenvolvimento de uma metodologia para previsão da velocidade do vento em conjunto com uma ferramenta de seleção profunda dos parâmetros de entrada. A estrutura do método consiste de múltiplos algoritmos de *machine learning* (RNA, SVM, *Gradient Boosting Machine* e *Random Forest*) em uma primeira parte e de algoritmos de mistura na segunda parte da estrutura. A RNA empregada é uma *feedforward*, com a função

de ativação sigmoide, treinada com o algoritmo de *backpropagation*. A metodologia de multi-modelos de *machine learning* com o procedimento de seleção profunda de variáveis de entrada superou a performance dos modelos de *benchmark* em cerca de 30 % no NRMSE para o horizonte de previsão de uma hora.

Wang et al. (2017) realizam pela primeira vez previsão probabilística de geração eólica utilizando o algoritmo de *deep learning* conhecido como redes neurais convolucionais (*Convolutional Neural Network* – CNN). O horizonte de previsão foi de 15 minutos até 8 horas à frente. Eles fizeram a escolha desse algoritmo, pois consideraram vantajoso a não realização de um pré-treinamento antes do treinamento da CNN. Já os algoritmos de *deep learning* conhecidos como *Deep Belief Networks* (DBN) e Stacked Denoising Auto-Encoder (SAE) precisam de um pré-treinamento que antecede o treinamento da rede.

Martín-Vázquez, Aler e Galván (2018) empregaram o método de *machine learning* com máquinas de vetores de suporte (SVM), com horizonte de previsão entre 3 e 15 horas com resolução de 3 horas, e variáveis do modelo de previsão numérica do tempo ECMWF. Eles realizaram duas abordagens: uma em que havia uma rede neural para cada horizonte de previsão, por exemplo, uma rede treinada com os dados de três horas, outra com os dados de seis horas, e assim por diante; já a outra abordagem era treinada com todos os dados entre 3 e 15 horas, a qual foi chamada de modelo global. Concluíram que a melhor abordagem era com o modelo global.

Khosravi, Machado e Nunes (2018) utilizaram diversos algoritmos de *machine learning*, dentre os quais redes neurais artificiais e máquinas de vetores de suporte, para prever a velocidade do vento até 30 minutos adiante no parque eólico de Osório, no Rio Grande do Sul. Os dados de entrada para os algoritmos eram os dados medidos pelas torres anemométricas.

## 2.6 SÍNTESE DOS RESULTADOS

A Tabela 1 apresenta a síntese dos estudos apresentados na seção 2.5.

Tabela 1- Síntese de resultados de artigos citados na seção 2.5.

Referência	Objetivo	Principais Resultados
Li et al. (2001)	Desenvolver a previsão de geração do parque eólico com redes neurais para cada turbina eólica	Os resultados indicaram que as redes neurais representa-

	e comparar com o método tradicional, o qual utiliza a curva de potência do fabricante.	ram melhor a geração das turbinas eólicas. O que foi justificado pelo fato de as redes neurais possuírem a habilidade de aprender os fatores que influenciam a previsão de geração.
Von-Bremen (2007)	Prever a geração, com horizonte de 48 horas e resolução horária, de um parque eólico no mar com redes neurais e os modelos de previsão numérica do tempo ECMWF e HIRLAM.	O esquema que combina a velocidade do vento extraída do ECMWF e HIRLAM como variáveis de entrada para a rede neural obteve o melhor resultado. O NRMSE obtido por este esquema foi de 15,8 %.
Cali et al. (2008)	Previsão de geração eólica, 24 horas à frente com resolução horária, empregando redes neurais artificiais para dois parques eólicos.	Os diferentes modelos NWP apresentaram erros de previsão de geração similares quando utilizados em redes neurais artificiais. O NRMSE obtido foi em torno de 10,5 %.
Salcedo-Sanz et al. (2009)	Aumentar a acurácia da previsão da velocidade do vento, no horizonte de 48 horas e resolução horária, com o uso de diferentes modelos NWP e bancos de redes neurais.	O conjunto de diferentes modelos NWP e bancos de redes neurais resultou em melhor acurácia na previsão da velocidade do vento quando comparada ao resultado obtido por uma rede neural com o melhor modelo NWP.

Zhao et al. (2012)	Apresentar um estudo para avaliar a performance e melhorar a acurácia de um sistema de previsão de geração, com horizonte de 24 horas e resolução de 10 min, para um parque eólico na China. Variáveis do WRF foram utilizadas em redes neurais artificiais para cada aerogerador nesta solução.	O menor NRMSE foi de 16,47 % da capacidade instalada do parque. Este valor foi obtido com a utilização do filtro de Kalman para eliminar os erros sistemáticos da velocidade do vento proveniente do WRF.
Alessandrini, Sperati e Pinson (2013)	Comparar dois modelos de previsões numérica do tempo <i>ensemble</i> (conjunto), ECMWF-EPS e COSMO-EPS, na previsão de geração eólica probabilística com uso de redes neurais artificiais, com horizonte de 72 horas e resolução de três horas, de um parque eólico. Realizou-se também previsão determinística com os modelos <i>ensemble</i> e o modelo ECMWF determinístico.	Os valores de NRMSE das previsões determinísticas ficaram entre 13 e 19 %. A previsão de geração eólica determinística obtida pela rede neural com variáveis de entrada provenientes do modelo determinístico ECMWF se mostrou um pouco melhor do que a obtida pelos modelos <i>ensemble</i> .
Artipoli e Durante (2014)	O trabalho deseja verificar a contribuição do modelo de mesoescala (WRF) em três diferentes sistemas de previsão de geração eólica que se utilizam de redes neurais artificiais. O horizonte de previsão foi de 72 horas e a resolução temporal horária. O estudo foi aplicado a	O esquema três, que empregou variáveis do GFS e WRF em conjunto em uma rede neural, obteve os menores erros de previsão. Os modelos de mesoescala são considerados importantes na previsão de geração de terrenos complexos. Os valores de NRMSE para o esquema três

	quatro parques situados em terrenos complexos no Sul da Itália.	dos quatro parques foram 14,2 %, 18,1 %, 15,6 % e 12,4 %.
Sergio e Ludermir (2015)	Aplicar três algoritmos (DBN, SDAE e MLP) de <i>deep learning</i> na previsão horária da velocidade do vento no Nordeste brasileiro e verificar o melhor resultado.	Os resultados do estudo não são conclusivos quanto ao melhor algoritmo para previsão da velocidade do vento para cada banco de dados.
Feng et al. (2017)	Desenvolver uma metodologia para previsão de velocidade do vento, com horizonte de uma hora à frente, em conjunto com uma ferramenta de seleção profunda dos parâmetros de entrada.	A metodologia proposta, com múltiplos modelos de <i>machine learning</i> e o procedimento de seleção profunda de variáveis de entrada, superou em cerca de 30 % os modelos de <i>benchmark</i> .
Wang et al. (2017)	Propor uma abordagem de previsão de geração eólica probabilística, com horizonte entre 15 min e 8 horas, baseada em <i>deep learning</i> e técnicas de <i>ensemble</i> .	Pela primeira vez redes neurais convolucionais (CNN) foram utilizadas para previsão de geração de energia eólica. A abordagem proposta foi superior aos demais modelos de <i>benchmark</i> , o que atribui-se ao uso de CNN e as técnicas de <i>ensemble</i> .
Martín-Vázquez, Aler e Galván (2018)	Testar o desempenho de dois sistemas de previsão de geração eólica baseados em máquinas de vetores de suporte (SVM). O primeiro sistema possuía uma SVM treinada para cada hora do	Constatou-se que o sistema treinado para todo o horizonte de previsão obteve o melhor desempenho.

	horizonte de previsão, entre 3 e 15 horas. Já o segundo era composto por uma SVM treinada para todo o horizonte de previsão.	
Khosravi, Machado e Nunes (2018)	Comparar a performance de diversos algoritmos de <i>machine learning</i> na previsão da velocidade do vento até 30 min adiante.	Os resultados indicaram que as redes neurais polinomiais do tipo <i>Group Method of Data Handling</i> (GMDH) obtiveram os melhores resultados para todos os bancos de dados.

### 3 METODOLOGIA

O presente capítulo engloba os métodos e procedimentos utilizados para execução deste trabalho. Os parques eólicos analisados, os modelos de previsão numérica do tempo, os esquemas de previsão de geração e os procedimentos são descritos a seguir.

#### 3.1 DESCRIÇÃO DOS PARQUES EÓLICOS

O estudo foi executado com base nos dados de dois parques eólicos, Ventos do Sertão e Aura Mirim II, localizados no Nordeste e no Sul do Brasil, respectivamente, ambos de propriedade da Atlantic Energias Renováveis S.A. A localização dos parques pode ser vista na Figura 9. Destaca-se que a distância entre eles é de aproximadamente 2800 km. Os dados de velocidade do vento foram tratados conforme o trabalho desenvolvido por Fuck (2016), já o tratamento aplicado aos dados de geração são descritos na seção que explica o aerogerador equivalente médio. Os valores de velocidade e direção do vento são obtidos em médias de 10 minutos.

Figura 9 - Localização dos parques eólicos de Sertão (SER) e Aura Mirim II (MIR-2).



Fonte: Modificado do Google Earth.

### 3.1.1 Parque eólico Ventos do Sertão

Ventos do Sertão é um dos seis parques eólicos que formam o Complexo Eólico de Morrinhos (CEMOR), situado no Nordeste na cidade de Campo Formoso que fica na região Centro Norte da Bahia, a 450 km de Salvador. CEMOR possui 180 MW de capacidade instalada por meio de 90 aerogeradores, dos quais 15 estão no parque eólico Ventos do Sertão (SER). O parque possui uma torre de medição anemométrica de referência (Latitude de  $-10,5548^\circ$ , Longitude de  $-40,5672^\circ$ ), identificada como AC7402, com três anemômetros de copo, duas veletas (*windvane*), um termômetro, um higrômetro e um barômetro com suas alturas indicadas na Tabela 2. Esses instrumentos possuem curvas de calibração reconhecidas por institutos internacionais.

Tabela 2 - Alturas dos instrumentos na torre anemométrica de medição do parque SER.

<b>Equipamento</b>	<b>Altura (m)</b>	<b>Marca/Modelo</b>
Anemômetro de copo	78,0	Vector/A100L2
Anemômetro de copo	76,0	Vector/A100L2
Veleta ( <i>windvane</i> )	76,0	Thies Clima/Compact
Termômetro	68,0	Vaisala/HMP 155
Higrômetro	68,0	Vaisala/HMP 155
Barômetro	68,0	Setra/276
Anemômetro de copo	50,0	Vector/A100L2
Veleta ( <i>windvane</i> )	48,0	Ornytion/207 P

A capacidade instalada no parque eólico Ventos do Sertão é de 30 MW. Os aerogeradores de 2 MW de potência nominal, modelo G97, de fabricação da Gamesa é utilizado em CEMOR. Esta turbina eólica tem altura de cubo (*hub*) de 78,0 m e diâmetro de rotor de 97,0 m. A Figura 10 mostra algumas turbinas eólicas do CEMOR, o mesmo está situado em um terreno complexo. A distribuição dos aerogeradores no complexo eólico pode ser vista na Figura 11 com destaque para o parque de Ventos do Sertão (SER). Coordenadas e elevação do terreno em relação ao nível do mar dos aerogeradores deste parque encontram-se no apêndice A. O complexo eólico de Morrinhos possui a direção do vento predominante de Leste-Sudeste (ESE),

como mostrado na rosa dos ventos na Figura 12, pois a região é influenciada pelos ventos alísios.

Figura 10 – Vista de eólicas do Complexo Eólico de Morrinhos.



Fonte: Atlantic Energias Renováveis S.A.

Figura 11 - Complexo de Morrinhos com aerogeradores e torre de referência (AC7402) do parque Sertão (SER) em destaque.

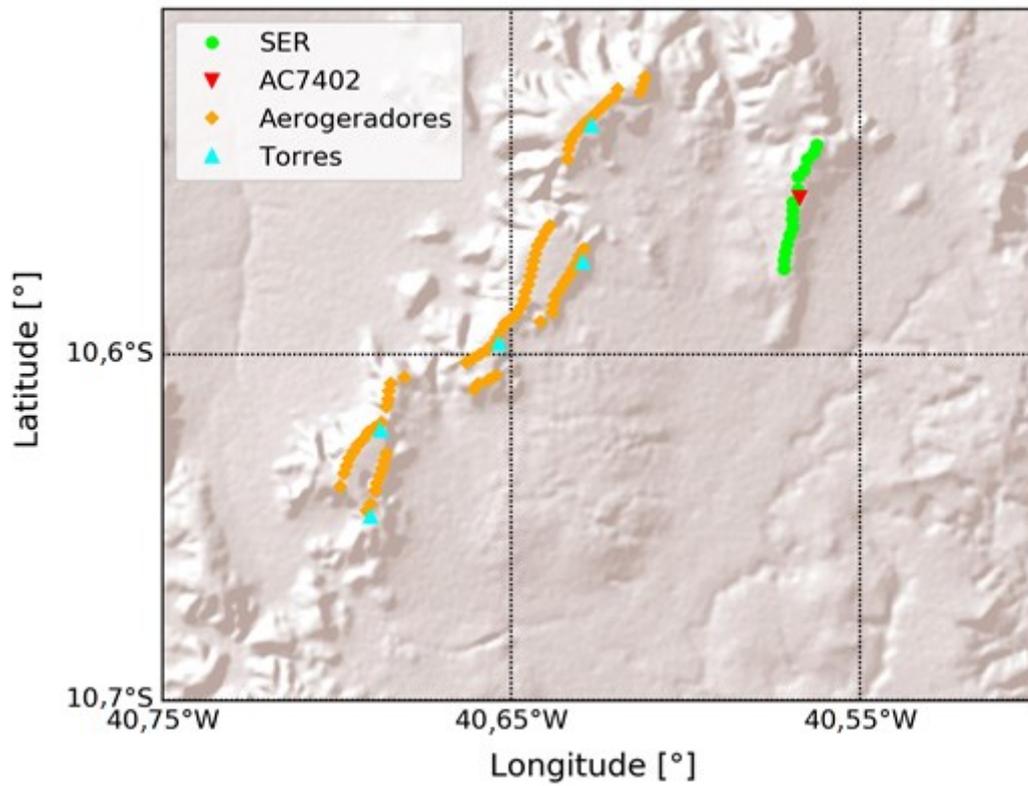
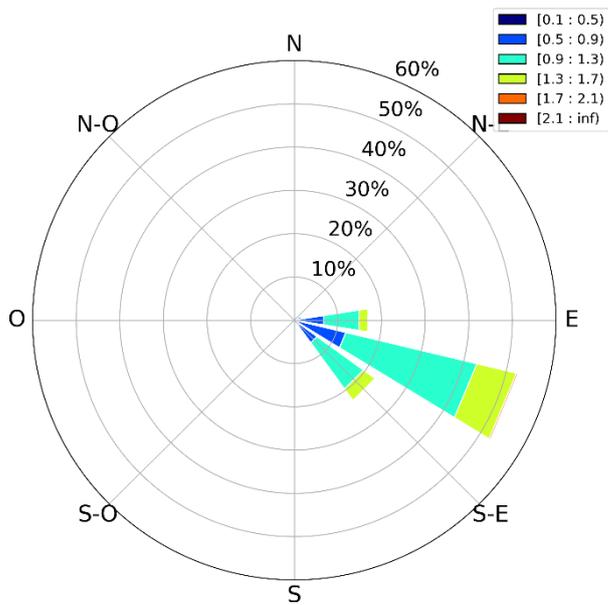


Figura 12 - Rosa dos ventos da torre AC7402 com velocidade normalizada pela velocidade média, construída com dados dos anos de 2017 e 2018.



### 3.1.2 Parque eólico Aura Mirim II

O parque eólico Aura Mirim II (MIR-2) faz parte do Complexo Eólico de Santa Vitória do Palmar (CESVP), localizado na região Sul do Brasil na cidade de Santa Vitória do Palmar, no litoral do extremo Sul do Rio Grande Sul (Figura 9). A torre de medição anemométrica do parque (Latitude de  $-33,1492^\circ$ , Longitude de  $-52,8939^\circ$ ), identificada como AC5312, é composta por três anemômetros, duas veletas (*windvane*), um termômetro, um higrômetro e um barômetro com suas posições mostradas na Tabela 3. Instrumentos que possuem suas curvas de calibração acreditadas por instituições internacionais.

Tabela 3 - Alturas dos instrumentos na torre anemométrica de medição do parque MIR-2.

<b>Equipamento</b>	<b>Altura (m)</b>	<b>Marca/Modelo</b>
Anemômetro de copo	120,0	Thies Clima/First Class
Anemômetro de copo	118,0	Thies Clima/First Class
Veleta ( <i>windvane</i> )	118,0	Thies Clima/First Class
Termômetro	110,0	Galtec/KPC 1/5
Higrômetro	110,0	Galtec/KPC 1/5
Barômetro	110,0	Amonit/AB60
Anemômetro de copo	57,5	Thies Clima/First Class
Veleta ( <i>windvane</i> )	56,0	Thies Clima/First Class

A capacidade instalada do parque é de 30 MW. O parque possui 10 aerogeradores, cujas posições e elevação do terreno em relação ao nível do mar encontram-se no apêndice A, do modelo AW 125/3000 fabricados pela Acciona Wind Power com 3 MW de potência nominal e diâmetro de rotor de 125,0 m. A altura do cubo é de 120,0 m. A Figura 13 apresenta uma vista de aerogeradores (AGs) do CESVP que possui 69 AGs e capacidade instalada de 207 MW. O parque MIR-2 está localizado no meio do complexo eólico e na beira de uma lagoa próxima ao mar, como pode ser visto na Figura 14. O terreno é considerado como simples. O regime de ventos possui uma direção prevalecente de Sudoeste (SO) e uma secundária em Nornoroeste (NNO), como se verifica na rosa dos ventos construída a partir de dados dos anos de 2017 e 2018 para a torre de referência de MIR-2, mostrada na Figura 15.

Figura 13 - Aeroeradores do Complexo Eólico de Santa Vitória do Palmar.



Figura 14 - Complexo de Santa Vitória do Palmar com aeroeradores e torre de referência (AC5312) do parque Aura Mirim II (MIR-2) em destaque.

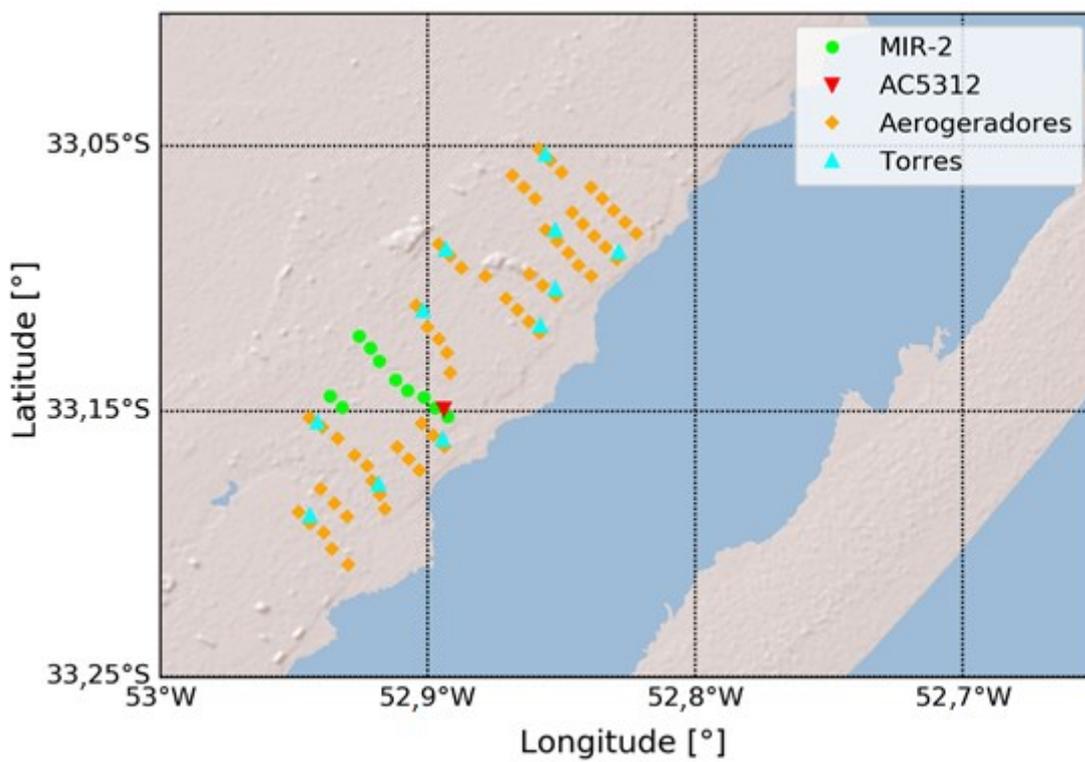
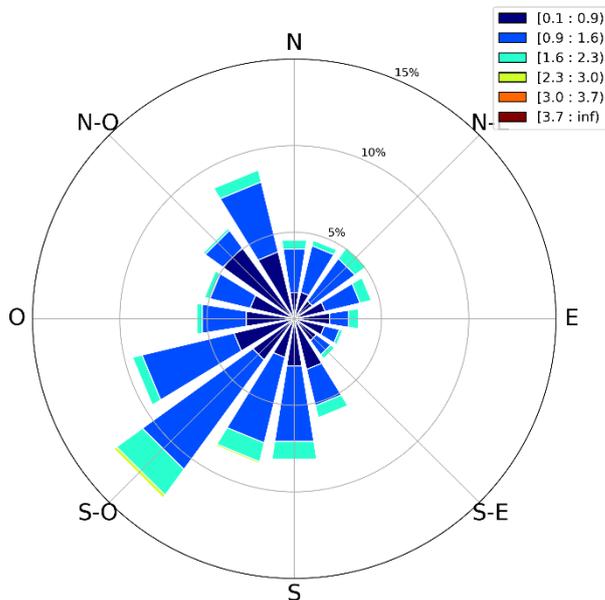


Figura 15 - Rosa dos ventos da torre AC5312 com velocidade normalizada pela velocidade média, construída com dados dos anos de 2017 e 2018.



### 3.2 MODELOS DE PREVISÃO NUMÉRICA DO TEMPO

Os modelos de previsão numérica do tempo utilizados no desenvolvimento desta pesquisa foram o *Global Forecast System* (GFS), o *Global Deterministic Forecast System* (GDPS) e o *Weather Research and Forecasting* (WRF). Estes se enquadram na categoria de modelos determinísticos, pois preveem um valor para o instante  $t$  ao invés de uma probabilidade. A seguir, serão detalhadas as características para cada modelo. Foram elaborados códigos na linguagem *Python* para efetuar as interpolações necessárias nos modelos de previsão do tempo. As bibliotecas *xarray*, *wrf-python*, *pandas*, *numpy*, entre outras, foram utilizadas no presente estudo.

#### 3.2.1 GFS 0,25°

O *Global Forecast System* (GFS) é um modelo de previsão numérica do tempo global desenvolvido pelo *National Centers for Environmental Prediction* (NCEP), que é uma instituição dos Estados Unidos. As previsões do GFS abrangem um período de até 16 dias e são feitas

quatro vezes ao dia nos seguintes horários 0000, 0600, 1200 e 1800 do Tempo Universal Coordenado (UTC). O NCEP disponibiliza dados do GFS nas resoluções espaciais horizontais de 0,25, 0,50 e 1,00 graus com 64 camadas híbridas sigma-pressão na vertical. Um modelo da atmosfera, um modelo de terra/solo, um modelo oceânico e um modelo gelo/mar acoplados em conjunto formam o modelo GFS. Mais informações podem ser encontradas no site do NCEP (2019). Neste trabalho utilizou-se o GFS com resolução espacial horizontal de 0,25 graus (aproximadamente 28,0 km) disponibilizado às 0000 UTC, o qual possui resolução temporal horária nas primeiras 120 horas, seguida de uma resolução a cada três horas das 120 às 240 horas e posteriormente saídas a cada 12 horas entre 240 e 384 horas. Os arquivos no formato GRIB2 com a saída horária do GFS 0,25° foram baixados do site do *NOAA Operational Model Archive and Distribution System* (NOAA, 2019). As Figuras 16 e 17 mostram, respectivamente, os pontos de grade do GFS 0,25° sobre o Complexo Eólico de Morrinhos (CEMOR) e o Complexo Eólico de Santa Vitória do Palmar (CESVP).

Figura 16 - Grade do GFS (0,25°) sobre o Complexo Eólico de Morrinhos com destaque em vermelho para a torre de referência do parque Sertão (AC7402).

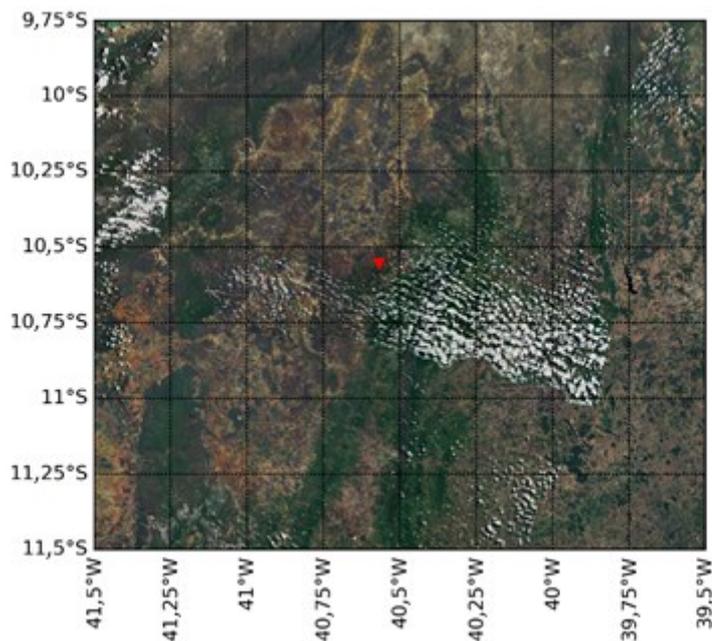
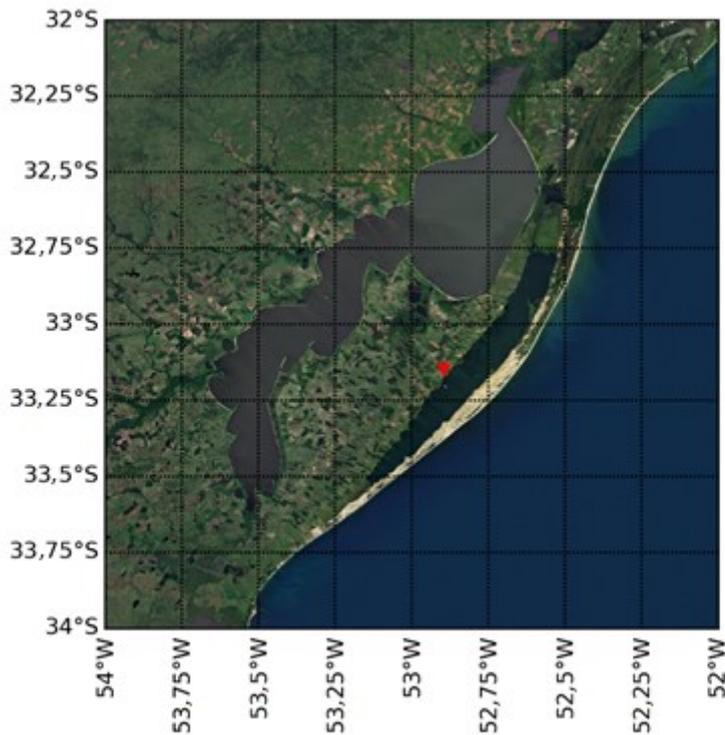


Figura 17 - Grade do GFS (0,25°) sobre o Complexo Eólico de Santa Vitória do Palmar com destaque em vermelho para a torre de referência do parque Aura Mirim II (AC5312).



### 3.2.2 GDPS 0,24°

O *Canadian Meteorological Centre* (CMC) é responsável pelo *Global Deterministic Prediction System* (GDPS), o qual é um modelo global de previsão numérica do tempo. O GDPS é disponibilizado gratuitamente com resolução espacial horizontal de 25 e 66 km, resolução vertical de 28 níveis isobáricos e resolução temporal de três horas. As previsões são feitas duas vezes ao dia, às 0000 e 1200 UTC com horizonte máximo de dez dias. Neste trabalho empregou-se o GDPS 0,24°, que possui aproximadamente 25 km de resolução espacial horizontal, disponibilizado às 0000 UTC. Os dados no formato GRIB2 foram baixados no site do Canadian Meteorological Centre (2019). Mais informações sobre este modelo de previsão do tempo podem ser encontrados na sua página na internet (CMC, 2019). Os pontos de grade no GDPS para CEMOR e CESVP podem ser vistos, respectivamente, nas Figuras 18 e 19.

Figura 18 - Grade do GDPS (0,24°) sobre o CEMOR com destaque para o a torre de referência do parque SER.

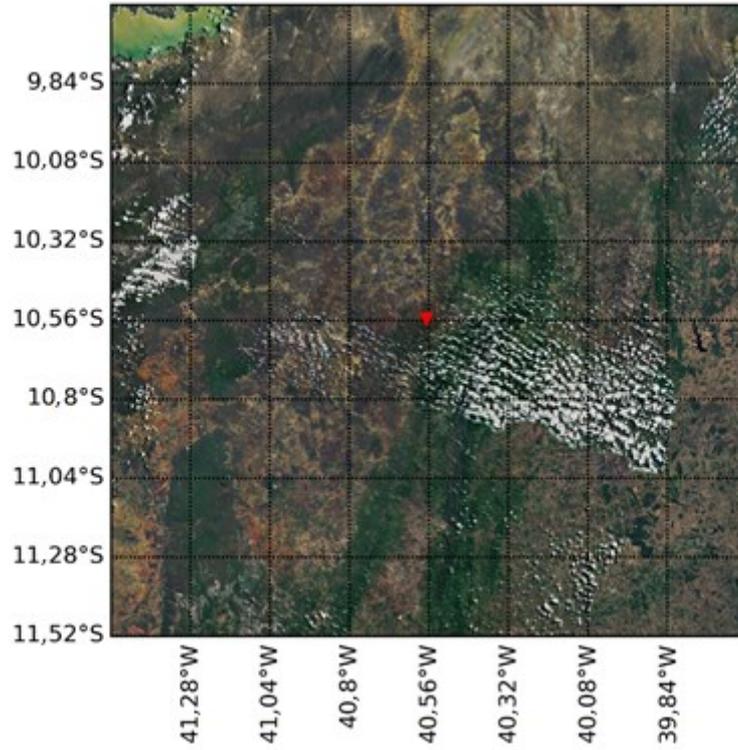
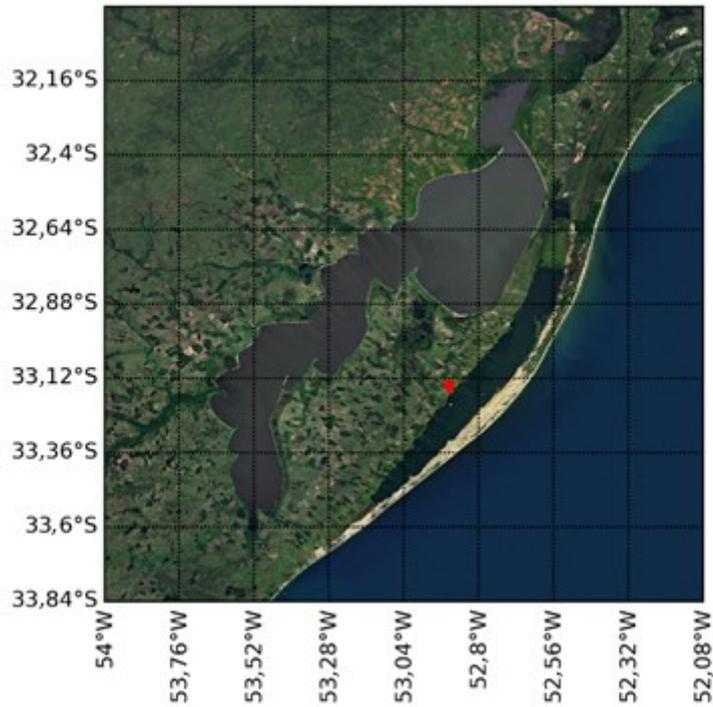


Figura 19 - Grade do GDPS (0,24°) sobre o CESVP com destaque para o a torre de referência do parque MIR-2.



### 3.2.3 WRF

O modelo *Weather Research and Forecasting* (WRF) é um modelo de previsão numérica de mesoescala desenvolvido nos Estados Unidos pelo esforço conjunto de diversas organizações governamentais e universidades. Este modelo é compressível, não-hidrostático, baseado nas equações de Euler (equações de Navier-Stokes com simplificações em que se considera o efeito das componentes dissipativas desprezível em relação às componentes convectivas), e conservativo para variáveis escalares, resolvido pelo método de diferenças finitas. As variáveis encontram-se desarranjadas na grade, pois a mesma é a grade horizontal do tipo C de Arakawa. Informações detalhadas sobre o modelo WRF podem ser encontradas na nota técnica do *National Center for Atmospheric Research* (NCAR) (SKAMAROCK et al., 2018).

A versão 3.9.1 do WRF foi empregada na execução deste trabalho. As condições iniciais e de contorno utilizadas neste trabalho para o WRF foram provenientes dos dados do modelo global GFS 0,25° das 1200 UTC com resolução temporal de três horas, os quais foram baixados do site que contém o arquivo histórico dos dados do NCEP GFS 0,25° (“NCEP GFS 0.25 Degree Global Forecast Grids Historical Archive”, 2015). As 15 primeiras horas de simulação foram descartadas, pois as mesmas são necessárias para inicialização da física do modelo. Foram estabelecidas duas grades, a maior (WRF-d01) com resolução horizontal de 12 km e a menor, aninhada, (WRF-d02) com 4 km, ambas com 28 níveis verticais. A projeção cônica conforme de Lambert foi a escolhida para gerar as grades com dados de topografia, tipo de solo e vegetação extraídas do *United States Geological Survey* (USGS) em uma resolução espacial de 2 min (aproximadamente 3,7 km). Estabeleceu-se uma resolução temporal de 10 min para os resultados das simulações no WRF. Os esquemas de parametrizações físicas empregadas, assim como a determinação das grades, para cada complexo eólico neste trabalho resultaram do desenvolvimento da pesquisa do time de WRF do projeto de P&D com a empresa Atlantic. O esquema de Similaridade de Monin-Obukhov (Janjic Eta) foi utilizado para camada limite superficial e o esquema TKE Mellor-Yamada-Janjic (Eta) para camada limite planetária em CESVP. No CEMOR, aplicou-se o esquema de Similaridade de Monin-Obukhov para camada limite superficial e o esquema YSU para camada limite planetária. As demais parametrizações se repetiram em ambos os complexos eólicos de acordo com o esquema RRTM, para radiação de onda longa, esquema Dudhia, para radiação de onda curta, esquema Lim, para microfísica

de nuvens, o modelo *Noah Land-Surface*, para física de superfície, e o esquema Kain-Fritsch (novo Eta) para parametrização de cumulus. O passo de tempo de 72 segundos foi aplicado nas simulações do WRF para ambos complexos eólicos. A Figura 20 mostra as grades do domínio d01 (12 km) e d02 (4 km) para o Complexo Eólico de Morrinhos e a Figura 21 para o Complexo Eólico de Santa Vitória do Palmar.

Figura 20 - (a) Grade do domínio d01 (12 km) e d02 (4km) sobre CEMOR; (b) Pontos de grade ao redor da torre de referência do parque Sertão.

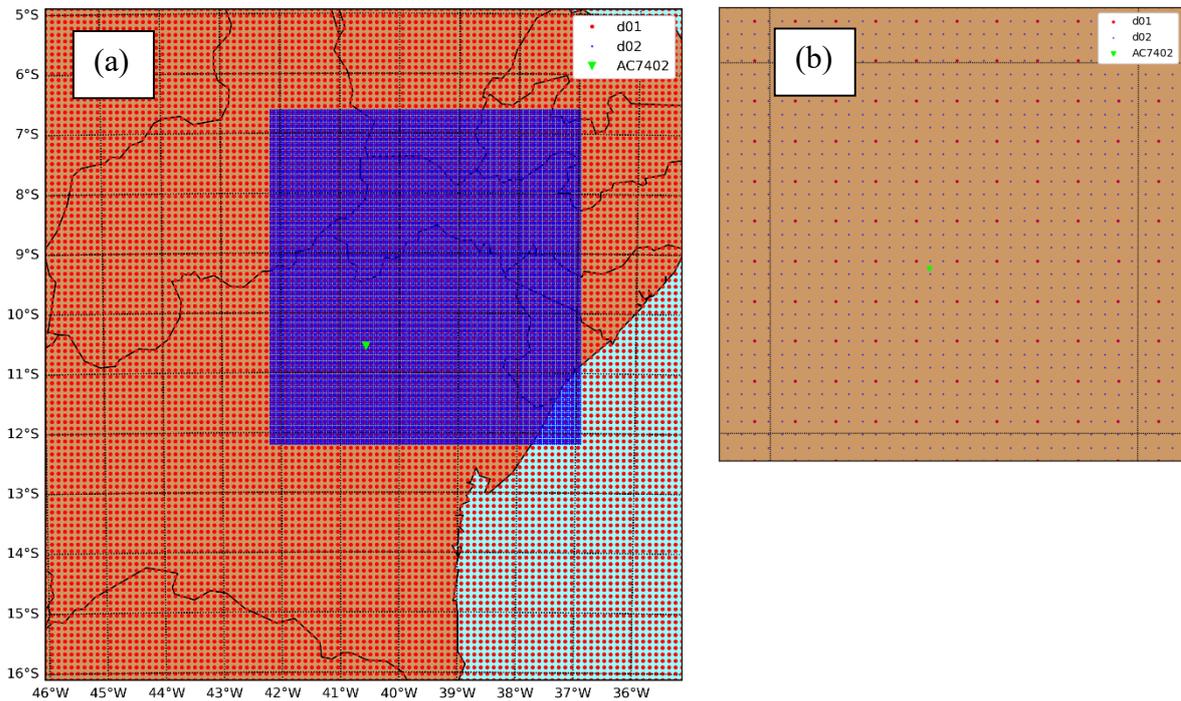
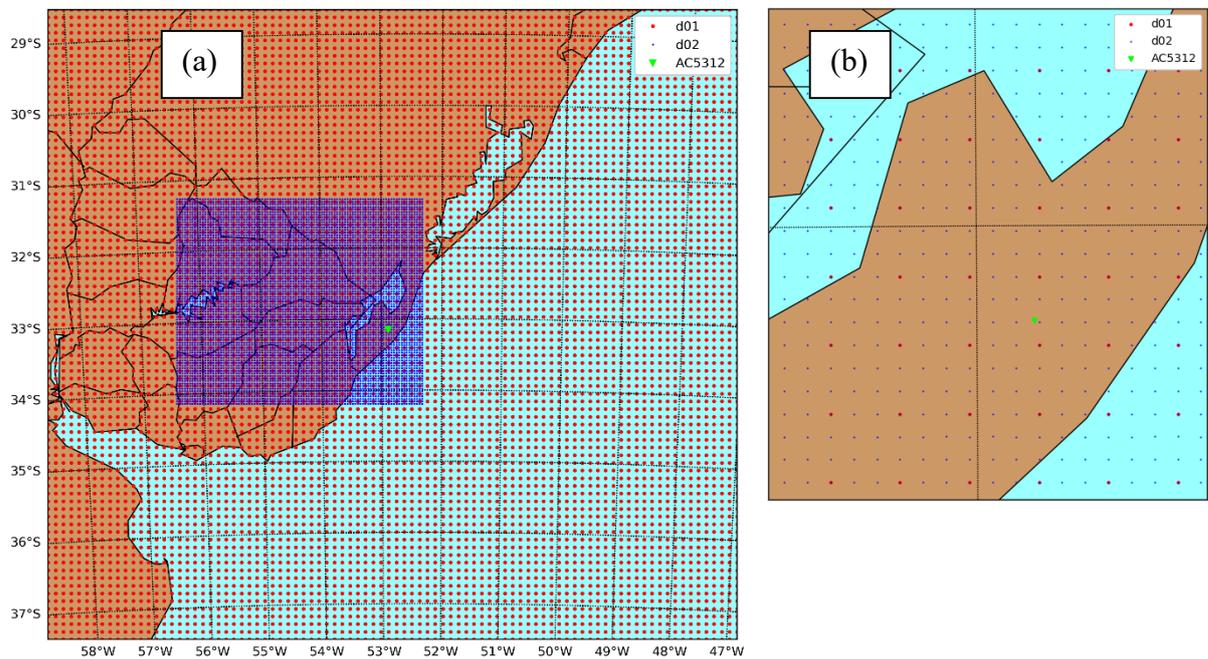


Figura 21 - (a) Grade do domínio d01 (12 km) e d02 (4km) sobre CESVP; (b) Pontos de grade ao redor da torre de referência do parque Aura Mirim II.



### 3.3 SELEÇÃO DE VARIÁVEIS

As variáveis de entrada podem influenciar o desempenho de modelos que empregam aprendizado de máquina (*machine learning*), por este motivo a seleção de variáveis é um procedimento importante. Neste trabalho, testaram-se diferentes conjuntos de variáveis de entrada para as redes neurais artificiais, que serão detalhados nas próximas seções. Um destes conjuntos foi resultante de um método de seleção de variáveis baseado na abordagem filtro com utilização do coeficiente de correlação de Pearson, o qual consistiu em: 1) calcular o coeficiente de correlação de Pearson entre todas as variáveis de entrada disponíveis no modelo NWP e o vetor da variável alvo (geração ou velocidade do vento); 2) reter variáveis com correlação em módulo maior que 0,20 no caso de MIR-2 e maior que 0,40 para SER (os valores de correlação de Pearson diferentes para cada parque foram escolhidos com base na quantidade de variáveis selecionadas); 3) calcular a correlação entre as variáveis resultantes da etapa 2 e eliminar uma das variáveis de conjuntos que apresentassem correlação de Pearson em módulo maior que 0,99 entre si.

### 3.4 CÁLCULO DO AEROGERADOR EQUIVALENTE MÉDIO

O aerogerador equivalente médio é obtido por meio da média aritmética da geração do parque calculada com base no número de aerogeradores em funcionamento no instante. Os dados utilizados para o cálculo do aerogerador equivalente médio passaram por filtros para que representassem melhor a realidade. As etapas de filtro dos dados foram as seguintes:

- Filtro pelo escore *Z*: este filtro tem por objetivo eliminar valores discrepantes em relação à média (*outliers*). Primeiramente, o escore *Z* (escore padrão) de cada aerogerador do parque em cada instante é calculado; posteriormente eliminam-se os dados com escore *Z* acima de 3 desvios padrões no caso do parque Aura Mirim II e acima de 2,5 desvios padrões para o parque Sertão. Os valores de 3 e 2,5 desvios padrões foram definidos com base em testes práticos. Esse filtro foi escolhido pelo fato do interesse da previsão ser no médio prazo, o qual não é prejudicado se houver casualmente a eliminação da geração em rampas e rajadas.
- Filtro de manutenção: o intuito deste filtro é remover dados de aerogeradores em manutenção. Uma turbina eólica é considerada em manutenção se a sua geração é nula ou negativa enquanto a velocidade medida na torre anemométrica está entre a velocidade de partida (*cut-in*) e velocidade de corte (*cut-out*). Eliminam-se o ponto considerado em manutenção e os pontos anterior e posterior a este.

### 3.5 PREVISÃO DE GERAÇÃO EÓLICA NO MÉDIO PRAZO

Diferentes abordagens de previsão de geração eólica foram testadas nesta pesquisa, sendo a abordagem física considerada a base para comparação em relação às abordagens com aprendizado de máquina (*machine learning*). As explicações das abordagens de previsão de geração aplicadas encontram-se nas subseções a seguir.

#### 3.5.1 Método físico

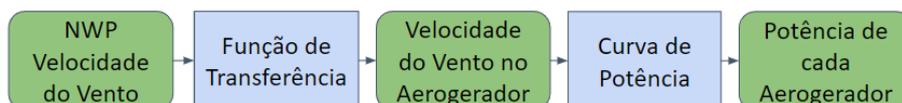
Na literatura, a abordagem física de previsão de geração considera que os modelos NWP levem em conta as características locais da área de estudo (orografia e modelagem física da atmosfera local) (CHANG, 2014), isto é o caso do modelo de mesoescala WRF, o mesmo

não acontece da mesma forma com os modelos globais GFS e GDPS, pois estes modelos consideram as características da superfície terrestre em baixa resolução. Entretanto, neste trabalho método físico designa a previsão da geração pela velocidade do vento na altura do cubo (*hub*), quando a mesma disponível ou no nível mais próximo, proveniente do modelo de previsão numérica do tempo (NWP) e a curva de potência do fabricante para o aerogerador do parque. A curva de potência do aerogerador é uma função que tem como entrada a velocidade, na altura da nacela, e como saída a potência.

A altura do cubo para os aerogeradores de SER e MIR-2 são 78,0 e 120,0 m, respectivamente. O modelo WRF permite a interpolação vertical das variáveis para a altura do cubo, já as velocidades do vento mais próximas da altura do cubo no modelo GFS ficam a 80,0 e 100,0 m acima do solo e no modelo GDPS nas alturas de 80,0 e 120,0 m. A velocidade proveniente do modelo WRF é normalizada em relação à massa específica do ar padrão da curva de potência ( $1,225 \text{ kg/m}^3$ ), com o auxílio da temperatura, umidade relativa e pressão, na altura do cubo obtidas do modelo. O mesmo não foi feito com as velocidades dos modelos globais, pois as variáveis de temperatura, umidade relativa e pressão não estavam disponíveis nos mesmos níveis da altura do cubo. As variáveis dos modelos de previsão do tempo são interpoladas horizontalmente na posição da torre de referência do parque.

O método físico consiste em: 1) interpolar a velocidade do vento na posição da torre de referência do parque, no caso do WRF a velocidade passa por normalização; 2) transferir a velocidade deste ponto para os pontos dos aerogeradores por meio de uma função de transferência, a qual foi obtida da regressão linear entre a velocidade medida na torre e a velocidade medida na nacela; 3) a velocidade na posição de cada aerogerador é utilizada na curva de potência do fabricante, obtendo-se assim a geração individual para cada aerogerador. O procedimento pode ser visto de forma simplificada no fluxograma mostrado na Figura 22. A geração total do parque é obtida somando-se a potência dos aerogeradores em funcionamento no momento.

Figura 22 - Fluxograma do método físico de previsão de geração.



### 3.5.2 Métodos com *machine learning*

Os métodos com *machine learning* consistiram no uso do algoritmo de aprendizagem supervisionada de redes neurais artificiais. As diferentes variáveis de entrada e topologias serão expostas na subseção 3.7. As subseções a seguir explicam os dois métodos que possuem algoritmos de *machine learning* no procedimento de previsão de geração eólica.

É importante ressaltar que antes de os dados dos modelos NWP serem utilizados nas redes neurais, eles passam por escalonamento, pois isso melhora o desempenho do algoritmo e deixa todas as variáveis na mesma escala. Nesta, a média do conjunto fica nula e o desvio padrão unitário. O escalonamento das variáveis ocorre por meio da equação 2 (GÉRON, 2017),

$$x_{novo} = \frac{x - \mu}{\sigma}, \quad (2)$$

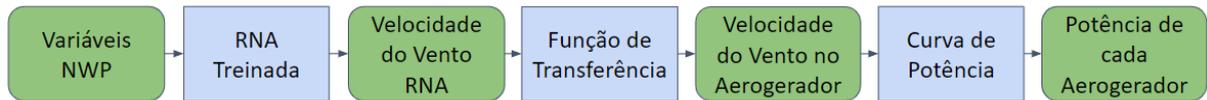
onde,  $x_{novo}$  é o dado escalonado,  $x$  é o dado original,  $\mu$  é a média dos dados e  $\sigma$  é o desvio padrão dos dados.

#### 3.5.2.1 Método de previsão de geração com a velocidade obtida por redes neurais artificiais

O método em questão se utiliza de redes neurais artificiais para prever a velocidade do vento, a qual é utilizada na curva de potência do fabricante do aerogerador. As redes neurais têm em sua camada de entrada as variáveis meteorológicas dos modelos de previsão numérica do tempo interpoladas na posição da torre anemométrica e em sua camada de saída a velocidade do vento na posição da torre anemométrica e na altura do cubo. As lacunas na série temporal de velocidade medida da torre anemométrica foram preenchidas por meio de regressão linear com os dados de velocidade medidos pelas demais torres do complexo eólico.

A Figura 23 mostra o fluxograma do método de previsão de geração eólica com redes neurais da velocidade do vento, que é composto pelas seguintes etapas: 1) as variáveis dos modelos de previsão do tempo são interpoladas horizontalmente na posição da torre anemométrica de referência do parque; 2) essas variáveis entram na rede neural treinada para prever a velocidade do vento na posição da torre e altura do cubo; 3) a velocidade prevista pela rede neural é transferida para as posições dos aerogeradores por meio da função de transferência mencionada no método físico; 4) essas velocidades são utilizadas na curva de potência do fabricante e resultam na geração individual de cada turbina eólica. A energia total gerada pelo parque, obtida da mesma maneira que no método físico, é a soma da geração dos aerogeradores em funcionamento no momento.

Figura 23 - Fluxograma do método de previsão de geração que utiliza redes neurais artificiais para prever a velocidade do vento na altura do cubo e na posição da torre.



### 3.5.2.2 Método de previsão de geração com o aerogerador equivalente médio obtido por redes neurais artificiais

O método utilizado nesta etapa foi proposto por Farias et al. (2019) e compreende o uso de redes neurais para prever diretamente a geração do aerogerador equivalente médio. O método segue o esquema da Figura 24, e consiste em: 1) interpolar horizontalmente as variáveis dos modelos de previsão do tempo na posição da torre anemométrica; 2) essas variáveis entram em uma rede neural treinada para prever a geração do aerogerador equivalente médio. Caso o valor previsto pela rede neural seja negativo, esse é substituído por zero; e se a geração prevista for maior que a potência nominal do aerogerador utilizado no parque, essa potência nominal substitui a geração que extrapola os limites do aerogerador real. A potência total gerada pelo parque é obtida com a multiplicação entre o número de turbinas eólicas em funcionamento no momento e a geração prevista do aerogerador equivalente médio.

Figura 24 - Fluxograma do método de previsão de geração que utiliza redes neurais artificiais para prever a potência gerada pelo aerogerador equivalente médio.



## 3.6 AVALIAÇÃO DAS PREVISÕES

### 3.6.1 Cálculos de erro

A diferença entre o valor medido e o previsto, classicamente, define o erro de previsão. As medidas de erro empregadas neste trabalho foram o erro médio (viés ou *bias*), viés normalizado (*normalized mean bias* - NMB), raiz do erro quadrático médio (*root mean squared error*

– RMSE), raiz do erro quadrático médio normalizada (*normalized root mean squared error* – NRMSE) e coeficiente de correlação de Pearson ( $r$ ). As equações destas medidas de erro encontram-se escritas, na Tabela 4, sendo  $P_{t+k}$  a potência medida no instante  $t+k$ ,  $\hat{P}_{t+k|t}$  a potência prevista para o instante  $t+k$  obtida por uma previsão realizada no tempo inicial  $t$ ,  $N$  é o número total de amostras e  $P_N$  é a potência nominal do aerogerador ou do parque eólico, no caso do erro para potência, e a velocidade média no caso para velocidade do vento.

Tabela 4 - Equações para mensurar o erro de um modelo de previsão.

Medida de erro	Fórmula
Erro de previsão	$e_{t+k t} = P_{t+k} - \hat{P}_{t+k t}$
Erro médio (viés)	$viés_k = \frac{1}{N} \sum_{t=1}^N e_{t+k t}$
Viés normalizado	$NMB_k = \frac{1}{N \cdot P_N} \sum_{t=1}^N e_{t+k t}$
Raiz do erro quadrático médio	$RMSE_k = \sqrt{\frac{1}{N} \sum_{t=1}^N (e_{t+k t})^2}$
Raiz do erro quadrático médio normalizada	$NRMSE_k = \frac{RMSE_k}{P_N}$
Coeficiente de correlação de Pearson	$r = \frac{cov(P, \hat{P})}{\sqrt{var(P) \cdot var(\hat{P})}}$

É importante quantificar as vantagens de um modelo sobre o modelo de referência (JUNG; BROADWATER, 2014), isto pode ser quantificado por

$$Imp_{EC,k} = \frac{EC_{ref,k} - EC_{adv,k}}{EC_{ref,k}}, \quad (3)$$

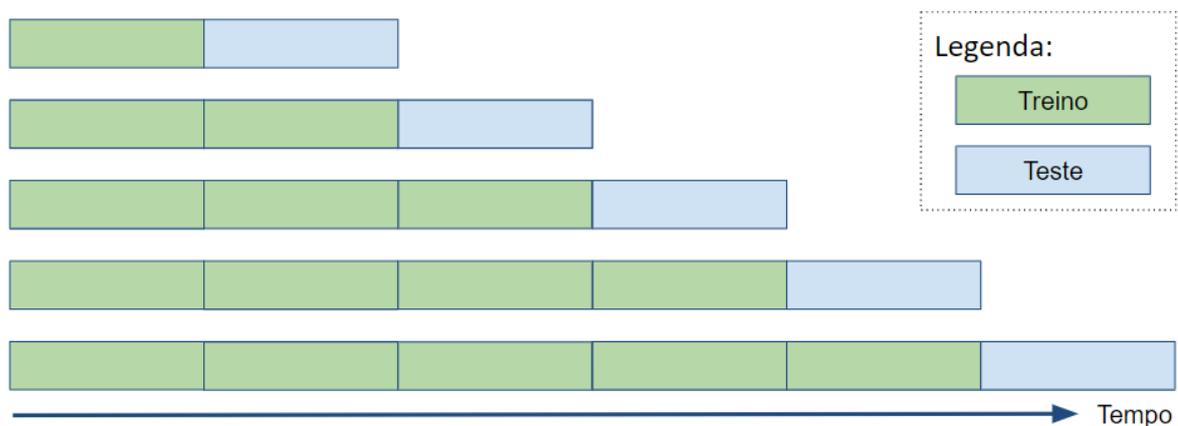
onde, EC indica o critério de avaliação utilizado, tal como o NRMSE.

### 3.6.2 Validação cruzada

A validação cruzada é a melhor maneira de avaliar o desempenho de um modelo de *machine learning* que emprega redes neurais artificiais com aprendizagem supervisionada, pois o modelo é treinado e testado diversas vezes com diferentes porções do banco de dados

(HYNDMAN; ATHANASOPOULOS, 2018). O procedimento de validação cruzada para série temporal *walking forward* (*walk forward validation*) foi empregado neste trabalho. A Figura 25 representa este procedimento, cada retângulo equivale ao período de previsão de 144 horas (seis dias). Os retângulos verdes indicam o banco de dados de treino e os azuis o banco de dados de teste. Deve-se observar que a cada teste da validação, ciclo, o banco de dados de treino vai aumentando.

Figura 25 - Representação da validação cruzada *walking forward*.



### 3.6.3 Diagrama de Taylor

O diagrama de Taylor foi criado com o objetivo de resumir estatisticamente a proximidade da previsão de modelos complexos ou de grandes quantidades de modelos aos dados reais observados. Isto ocorre por meio da representação gráfica do coeficiente de correlação de Pearson ( $r$ ), da raiz da diferença quadrática média centrada (RMSD) e do desvio padrão em uma imagem (TAYLOR, 2001). Neste trabalho, a RMSD e o desvio padrão foram normalizados em relação à potência nominal dos parques eólicos. A raiz da diferença quadrática média centrada normalizada (NRMSD) é equivalente ao NRMSE sem o viés, por este motivo possui um valor menor (WARNER, 2011). O relacionamento entre as três métricas de erro do diagrama de Taylor se dá pela equação 4,

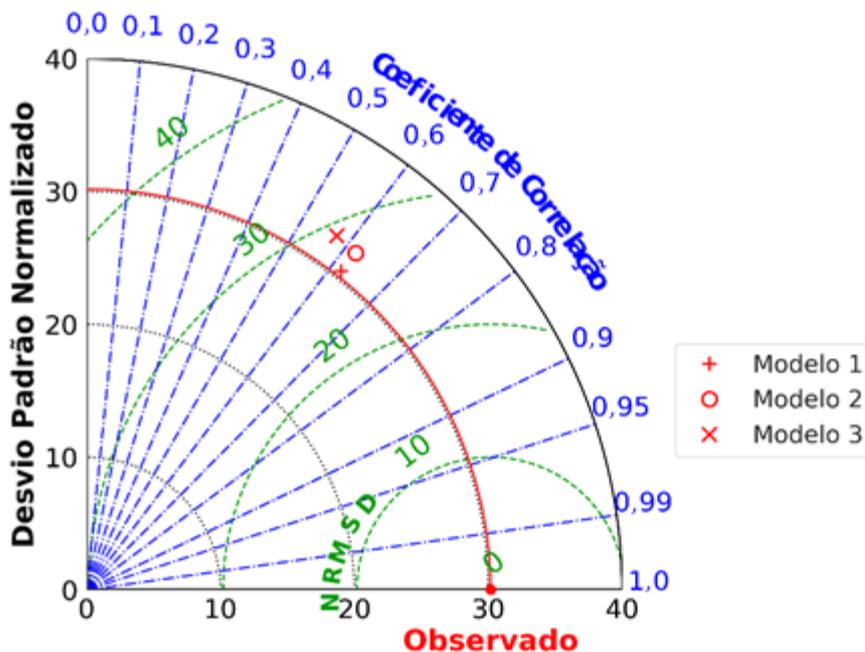
$$NRMSD = \frac{1}{P_N} \cdot \sqrt{(\sigma_f^2 + \sigma_r^2 - 2\sigma_f\sigma_r r)}, \quad (4)$$

onde,  $P_N$  é a potência nominal do parque,  $\sigma_f$  é o desvio padrão da previsão,  $\sigma_r$  é a previsão dos dados observados e  $r$  é o coeficiente de correlação de Pearson. O gráfico do diagrama de Taylor

é construído com base na Lei dos Cossenos. Para quantificar quão bem um modelo representa os dados reais por meio do diagrama de Taylor é importante se basear na razão entre o desvio padrão da previsão e dos dados observados, no coeficiente de correlação de Pearson entre a previsão e dado observado e no valor de NRMSD (MCAVANEY et al., 2001). Se a distância entre o ponto que representa o modelo de previsão é pequena em relação ao ponto observado, há boa concordância entre os mesmos.

A Figura 26 mostra um exemplo da representação estatística de três modelos em um diagrama de Taylor. Pode-se observar que os modelos 1 e 2 possuem o coeficiente de correlação de 0,62 em relação aos dados observados, enquanto que o modelo 3 possui um coeficiente de correlação de 0,57. O modelo 1 possui o desvio padrão normalizado de 30,6 %, que é muito próximo do apresentado na linha vermelha que se refere aos dados reais, isto indica que esse modelo representa bem as variações que ocorrem na realidade. O menor NRMSD foi de 26,5 % e resultou do modelo 1. Com base na análise, o modelo 1 seria o que representaria melhor os dados observados, pois é o modelo que tem a maior proximidade do desvio padrão dos dados observados e a menor distância para o ponto observado, este destacado como o ponto vermelho.

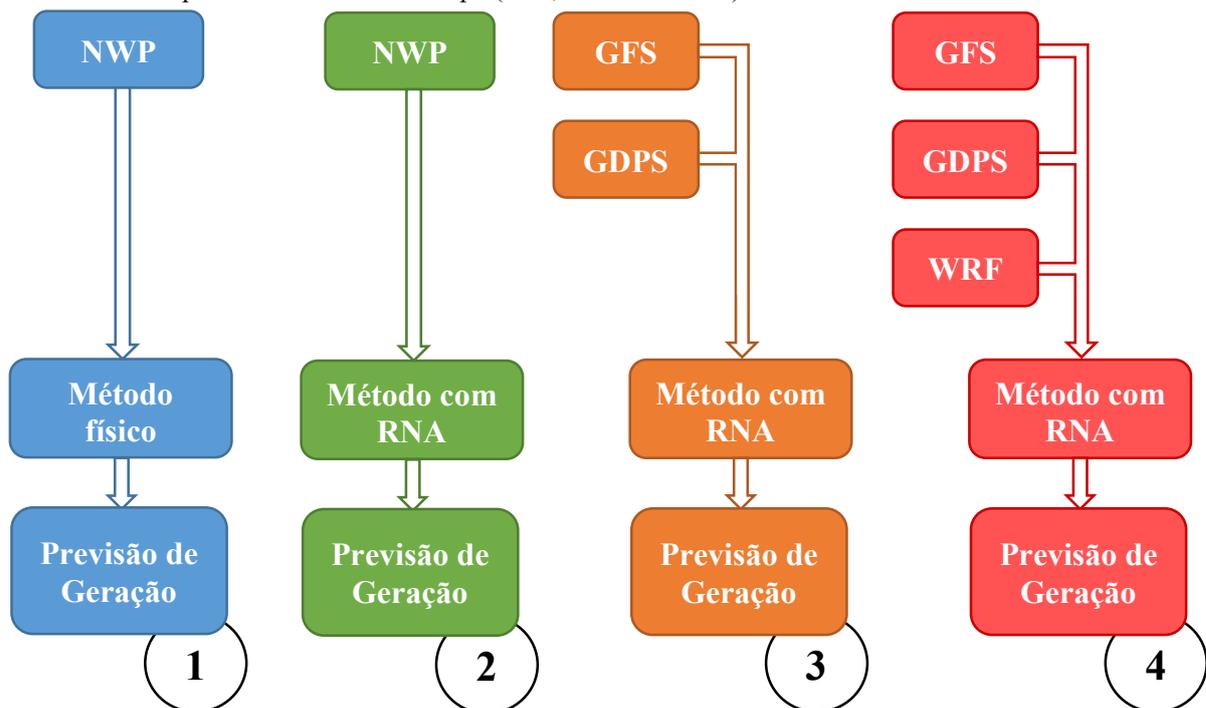
Figura 26 - Exemplo do diagrama de Taylor com a representação estatística de três modelos.



### 3.7 PROCEDIMENTO DE PESQUISA

O procedimento da pesquisa compreendeu os testes de quatro esquemas com os métodos de previsão de geração, os quais podem ser vistos na Figura 27, onde método com RNA indica um dos métodos com *machine learning*. O esquema 1 se utiliza de um modelo de previsão numérica do tempo (GFS, GDPS ou WRF) e o modelo físico. O esquema 2 emprega um modelo de previsão numérica do tempo (GFS, GDPS ou WRF) e um dos modelos com *machine learning*, que pode ser o modelo que prevê a velocidade ou o que prevê o aerogerador equivalente médio. O esquema 3 emprega variáveis dos modelos globais GFS e GDPS e um dos modelos com *machine learning*. O esquema 4 emprega os dois modelos globais disponíveis e o modelo de mesoescala WRF em sua grade d01 em um dos modelos com aprendizado de máquina.

Figura 27 - Esquemas a serem testados com os métodos de previsão de geração eólica, onde NWP remete a um dos modelos de previsão numérica do tempo (GFS, GDPS ou WRF).



A Tabela 5 concatena as informações sobre os modelos de previsão numérica do tempo utilizados neste estudo. Nos modelos GFS e GDPS, modelos globais, realizou-se interpolação espacial horizontal na posição da torre e interpolação temporal para que sua resolução temporal se torne de 10 minutos, visto que a previsão da geração do parque eólico com esta resolução é

o objetivo. Já o modelo de mesoescala WRF teve suas variáveis transportadas para o ponto de grade de massa, as quais posteriormente passaram por interpolação horizontal para o ponto da torre e interpolação vertical para os níveis desejados. As interpolações horizontal espacial e temporal foram do tipo linear, já a interpolação vertical interpola os campos para as superfícies nos níveis especificados. O número de variáveis mostrado na Tabela 5 considera como variáveis diferentes a mesma propriedade física se ela se encontrar em um nível diferente, por exemplo, a temperatura em 1000 mbar e 1100 mbar são contabilizadas como duas variáveis.

Tabela 5 - Informações sobre os modelos de NWP utilizados no estudo.

<b>Informação</b>	<b>GFS</b>	<b>GDPS</b>	<b>WRF</b>
Resolução Horizontal	0,25° (~28 km)	0,24° (~ 25 km)	d01 – 12 km d02 – 4 km
Níveis verticais	32	28	28
Resolução temporal	horária entre 0 e 120 horas; de três em três horas de 120 até 240 horas	três horas	10 minutos
Dados de entrada	-	-	GFS 0,25° (1200 UTC) de 3 em 3 horas
Nº de variáveis	426	213	802 em SER 846 em MIR-2

Os esquemas 2, 3 e 4, que empregaram os métodos com *machine learning*, foram testados com diversas variáveis de entrada, as quais se dividiram em nove grupos denominados de A até I. Esses grupos basicamente são constituídos por:

- A. Velocidade do vento mais próxima ou na altura do cubo;
- B. Velocidade do vento mais próxima ou na altura do cubo e hora decimal;
- C. Velocidade do vento mais próxima ou na altura do cubo, hora decimal e tempo de simulação;
- D. Velocidade e direção do vento mais próxima ou na altura do cubo;
- E. Velocidade, direção, temperatura, umidade relativa e pressão mais próxima ou na altura do cubo;

- F. Componentes U e V da velocidade do vento mais próxima ou na altura do cubo e hora decimal;
- G. Componentes U e V em diversas altitudes e hora decimal;
- H. Componentes U e V, temperatura, pressão atmosférica e outras variáveis disponíveis em cada modelo;
- I. Variáveis selecionadas pela abordagem de filtro por correlação de Pearson.

A Tabela 6 mostra as variáveis nos níveis considerados desses grupos em cada modelo, porém as variáveis do grupo I estão no apêndice B. Nessa tabela as variáveis são:  $v$  – velocidade do vento; HD – hora decimal; TS – tempo de simulação;  $d$  - direção do vento; T- temperatura; UR - umidade relativa; SPFH - umidade específica; P - pressão atmosférica; U – componente U da velocidade do vento; V – componente V da velocidade do vento; PBLH – altura da camada limite; UST -  $u_*$  da teoria de similaridade; HFX – fluxo de calor para cima na superfície; TKE\_PBL – energia cinética turbulenta da camada limite atmosférica; QVAPOR – taxa de mistura de vapor de água; W – componente W da velocidade do vento. O esquema 2 utiliza apenas dados de um modelo de previsão numérica do tempo por vez, já os esquemas 3 e 4 utilizam as variáveis indicadas nos grupos de seus modelos NWP. Por exemplo, o esquema 3 com o conjunto de variáveis A terá como variáveis de entrada a velocidade mais próxima ou na altura do cubo do GFS e do GDPS.

Tabela 6 - Variáveis testadas de cada modelo NWP testadas com os esquemas de previsão de geração.

ID	SER			MIR-2		
	GFS	GDPS	WRF	GFS	GDPS	WRF
A	$v$ em 80 m		$v$ em 78 m	$v$ em 100 m	$v$ em 120 m	
B	$v$ em 80 m; HD		$v$ em 78 m; HD	$v$ em 100 m; HD	$v$ em 120 m; HD	
C	$v$ em 80 m; HD, TS		$v$ em 78 m; HD, TS	$v$ em 100 m; HD, TS	$v$ em 120 m; HD, TS	
D	$v$ e $d$ em 80 m		$v$ e $d$ em 78 m	$v$ e $d$ em 100 m	$v$ e $d$ em 120 m	

<b>E</b>	$v$ , $d$ , $T$ e $P$ em 80 m; UR em 1000 mb	$v$ e $d$ em 80 m; $T$ e SPFH em 1000 mb; $P$ na superfície	$v$ , $d$ , $T$ , $P$ e UR em 80 m	$v$ , $d$ e $T$ em 100 m; $P$ em 80 m; UR em 1000 mb	$v$ e $d$ em 120 m; $T$ e SPFH em 1000 mb; $P$ na superfície	$v$ , $d$ , $T$ , $P$ e UR em 120 m
<b>F</b>	U e V em 80 m; HD		U e V em 78 m; HD	U e V em 100 m; HD	U e V em 120 m; HD	
<b>G</b>	U e V em 10, 80 e 100 m; HD	U e V em 10, 40, 80 e 120 m; HD		U e V em 10, 80 e 100 m; HD	U e V em 10, 40, 80 e 120 m; HD	
<b>H</b>	U e V em 10, 80 e 100 m; $T$ em 2, 80 e 100 m; $P$ em 80 m; PBLH	U e V em 10, 40, 80 e 120,0 m; $T$ em 80,0 m; $P$ na superfície	UST; HFX; PBLH; U e V em 10 m; U, V, W, TKE_PBL, $P$ e QVAPOR em 40, 57,5, 80, 100, 120, 140, 160, 180, 200, 250, 300, 400, 500 e 1000 m	U e V em 10, 80 e 100 m; $T$ em 2, 80 e 100 m; $P$ em 80 m; PBLH	U e V em 10, 40, 80 e 120,0 m; $T$ em 80,0 m; $P$ na superfície	UST; HFX; PBLH; U e V em 10 m; U, V, W, TKE_PBL, $P$ e QVAPOR em 40, 48, 50, 76, 78, 80, 100, 120, 140, 160, 180, 200, 250, 300, 400, 500 e 1000 m
<b>I</b>	Variáveis obtidas pelo método de seleção de variáveis (ver apêndice B).					

Diferentes topologias de redes neurais artificiais foram testadas junto aos esquemas 2, 3 e 4. O número de neurônios na camada de entrada variou conforme a quantidade de variáveis de entrada utilizada, já as camadas escondidas tinham sempre número igual de neurônios e a camada de saída possuía apenas um neurônio que era a velocidade do vento para a torre anemométrica na altura do cubo ou a geração do aerogerador equivalente médio. Redes neurais artificiais multicamadas perceptron (*Multilayer Perceptron* – MLP) foram utilizadas neste trabalho com uma, duas e três camadas escondidas. Essas redes neurais, após treinamento, permitem que as informações caminhem da camada de entrada para a camada de saída, o que caracteriza uma rede alimentada adiante (*feedforward*, em inglês). As informações sobre os hiperparâmetros para cada topologia das redes MLP são mostradas na Tabela 7. Os algoritmos foram

aplicados com o auxílio da linguagem livre de programação *Python* e a biblioteca de inteligência artificial Keras com o Tensorflow como *backend*. As redes neurais testadas possuíam todos os neurônios conectados, caracterizando redes densas. O treinamento das redes neurais ocorreu por meio do método de retropropagação do erro (*backpropagation*) com o otimizador Adam sendo o erro quadrático médio (MSE) a função custo (*loss function*, em inglês).

Tabela 7 - Hiperparâmetros empregados nas redes neurais MLP testadas.

<b>Hiperparâmetros</b>	<b>MLP 1 camada escondida</b>	<b>MLP 2 camadas escondidas</b>	<b>MLP 3 camadas escondidas</b>
Nº de neurônios por camada escondida	1, 5, 10, 20, 30, 40, 50		
Função de ativação das camadas escondidas	Tangente Hiperbólica (tanh)	ReLU	
Função de ativação da camada de saída	Linear		
Otimizador	Adam		
Taxa de aprendizagem	0,001		
Tamanho do lote ( <i>Batch size</i> )	32		
Número máximo de épocas	5000		

O treinamento e teste das redes neurais ocorreram em ciclos, conforme a validação cruzada *walking forward* explicada na seção 3.6.2. O banco de dados analisado para os parques Ventos do Sertão e Aura Mirim II se inicia em 23/12/2017 às 00:00 e termina em 09/05/2018 às 23:50, totalizando 138 dias, em que é considerada hora local sem horário de verão. Esse período corresponde a períodos do verão e do outono. Cada seis dias no banco de dados dos modelos de previsão numérica do tempo são constituídos por uma rodada do modelo, visto que o objetivo é a previsão de 144 horas. A Tabela 8 mostra os bancos de dados de treino e teste em cada ciclo da validação cruzada.

Tabela 8 - Bancos de dados de treino e teste em cada ciclo da validação cruzada.

Ciclo	Treino		Teste	
	Início	Fim	Início	Fim
0	23/12/2017	28/12/2017	29/12/2018	03/01/2018
1	23/12/2017	03/01/2018	04/01/2018	09/01/2018
2	23/12/2017	09/01/2018	10/01/2018	15/01/2018
3	23/12/2017	15/01/2018	16/01/2018	21/01/2018
4	23/12/2017	21/01/2018	22/01/2018	27/01/2018
5	23/12/2017	27/01/2018	28/01/2018	02/02/2018
6	23/12/2017	02/02/2018	03/02/2018	08/02/2018
7	23/12/2017	08/02/2018	09/02/2018	14/02/2018
8	23/12/2017	14/02/2018	15/02/2018	20/02/2018
9	23/12/2017	20/02/2018	21/02/2018	26/02/2018
10	23/12/2017	26/02/2018	27/02/2018	04/03/2018
11	23/12/2017	04/03/2018	05/03/2018	10/03/2018
12	23/12/2017	10/03/2018	11/03/2018	16/03/2018
13	23/12/2017	16/03/2018	17/03/2018	22/03/2018
14	23/12/2017	22/03/2018	23/03/2018	28/03/2018
15	23/12/2017	28/03/2018	29/03/2018	03/04/2018
16	23/12/2017	03/04/2018	04/04/2018	09/04/2018
17	23/12/2017	09/04/2018	10/04/2018	15/04/2018
18	23/12/2017	15/04/2018	16/04/2018	21/04/2018
19	23/12/2017	21/04/2018	22/04/2018	27/04/2018
20	23/12/2017	27/04/2018	28/04/2018	03/05/2018
21	23/12/2017	03/05/2018	04/05/2018	09/05/2018

## 4 RESULTADOS

Este capítulo apresenta os resultados obtidos pela aplicação dos métodos descritos no capítulo anterior. Os resultados da seleção de variáveis pela abordagem do filtro com a correlação de Pearson são apresentados, assim como a obtenção do melhor representante de cada método de previsão para a realização de uma comparação entre os mesmos. Vale lembrar que os valores medidos tanto para a geração quanto para a velocidade, mostrados abaixo, são em médias de dez minutos e o período estudado vai de 23/12/2017 até o fim do dia 09/05/2018.

### 4.1 SELEÇÃO DE VARIÁVEIS

A seleção de variáveis por meio do filtro e correlação de Pearson, descrita na seção 3.3, originou as variáveis utilizadas no grupo I, conforme citado na seção 3.7. O apêndice B mostra todas as variáveis selecionadas para cada modelo NWP em relação aos dois parques e à variável desejada a ser prevista pela rede neural artificial. A Tabela 9 mostra o número de variáveis selecionadas para cada uma das redes neurais que têm por objetivos prever a velocidade do vento e a geração do aerogerador equivalente médio em cada parque. Lembrando que para a variável ser selecionada, os valores da correlação de Pearson tinham de ser maior ou igual a 0,40 ou 0,20 para os parques de Ventos do Sertão (SER) ou de Aura Mirim II (MIR-2), respectivamente. Observa-se que apesar de a correlação necessária ser maior para o parque de Ventos do Sertão, o número de variáveis também foi maior. Isso indica que há uma maior correlação entre as variáveis dos modelos NWP e os dados de SER. O parque MIR-2 apresentou um número menor de variáveis, mesmo com o coeficiente de correlação escolhido para o corte menor do que no parque SER, o que indica pouca dependência linear entre as variáveis e o alvo da previsão.

Tabela 9 - Números de variáveis obtidos pelo método de seleção por meio do coeficiente de Pearson para: a velocidade do vento na torre anemométrica de referência e altura do cubo; e para o aerogerador equivalente médio.

Modelo	Velocidade do vento		Aerogerador equivalente	
	SER	MIR-2	SER	MIR-2
GFS	39	9	39	6
GDPS	27	11	26	13

<b>WRF-d01</b>	32	20	33	14
<b>WRF-d02</b>	32	20	31	11

## 4.2 PREVISÃO DE GERAÇÃO EÓLICA DO PARQUE PELO MÉTODO FÍSICO

O método físico, explicado na subseção 3.5.1, foi aplicado com os modelos de previsão numérica do tempo GFS, GDPS, WRF-d01 e WRF-d02, seguindo a lógica do esquema 1, mostrado na seção 3.7. Nas subseções, a seguir, encontram-se os resultados comparativos da previsão da velocidade do vento diretamente dos modelos NWP e da geração de energia para os parques eólicos Ventos do Sertão e Aura Mirim II.

### 4.2.1 Previsão de velocidade pelos modelos NWP

A Figura 28 mostra a série temporal dos valores da velocidade do vento medida na torre de referência do parque Ventos do Sertão, na altura do cubo, além dos valores de velocidade previstos pelos modelos NWP, com interpolação na posição da torre anemométrica. As velocidades do vento no GFS e GDPS, são para uma altura de 80,0 m, acima do solo, enquanto que para as grades do WRF são para uma altura de 78,0 m, correspondendo à mesma altura do cubo. A série temporal não indica tantos pontos abruptos de alta e baixa velocidades, visto que poucas vezes há picos extremos da curva dos dados medidos, curva preta. Há uma certa constância na série, decorrente da forte influência dos ventos alísios na região, o que se confirma, também, pela direção constante do vento conforme evidenciada pela rosa dos ventos, na subseção 3.1.1. Visualmente, o GDPS indica uma velocidade menor que a medida em diversos momentos da série temporal. Com o intuito de avaliar com maior acerto o desempenho de cada modelo NWP para o parque SER criou-se a Tabela 10. O NRMSE e NMB são normalizados em relação à velocidade média. Observa-se que o GDPS possui as piores métricas, RMSE de 2,90 m/s, viés de 2,09 m/s e r de 0,58. O GFS obteve um resultado melhor com RMSE de 2,37 m/s, viés de 1,68 e r de 0,69. O melhor modelo para SER foi o WRF com a grade d01 e RMSE de 1,82 m/s, viés de 0,07 e r de 0,67, isso indica que não há necessidade do aninhamento, neste caso.

Figura 28 - Série temporal da velocidade do vento medida, em médias de dez minutos, e da prevista pelos diferentes modelos NWP para o parque de Sertão.

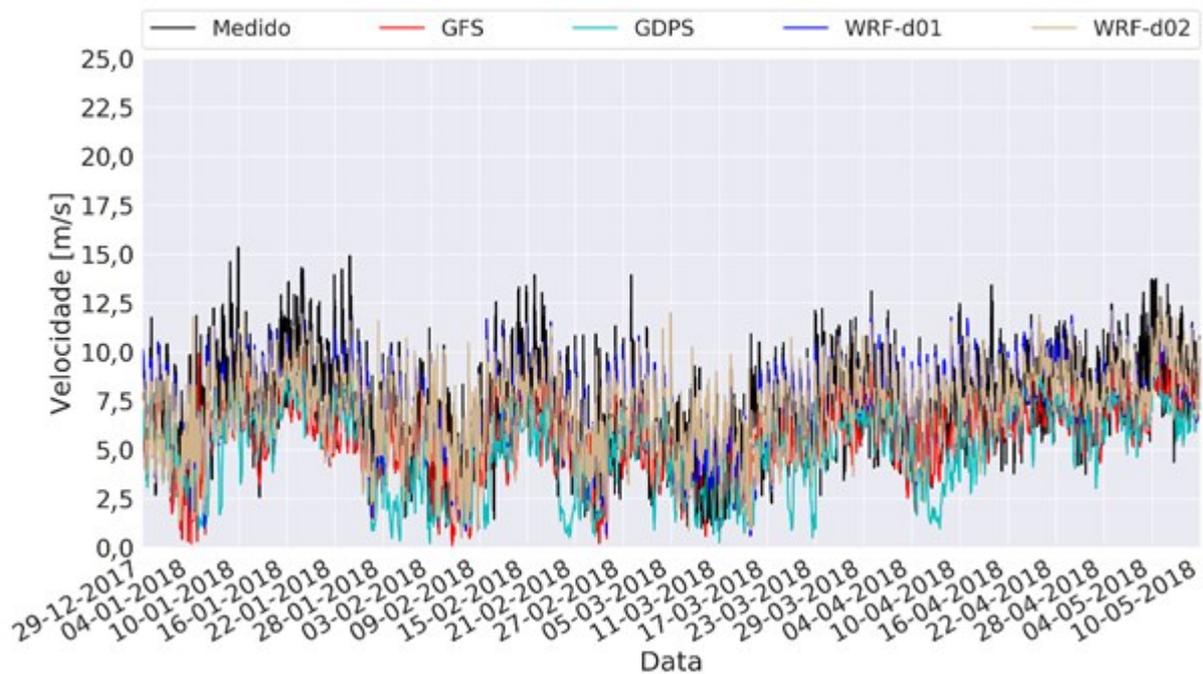


Tabela 10 - Métricas de erro para previsão de velocidade pelos modelos NWP para o parque Ventos do Sertão.

Modelo	RMSE [m/s]	viés [m/s]	NRMSE [%]	NMB [%]	r
GFS	2,37	1,68	33,0	23,3	0,69
GDPS	2,90	2,09	40,3	29,1	0,58
WRF-d01	1,82	0,07	25,3	1,0	0,67
WRF-d02	1,86	0,14	25,9	1,9	0,63

A série temporal da velocidade do vento, medida na torre de referência do parque Aura Mirim II, e altura do cubo e da velocidade do vento prevista pelos modelos NWP pode ser vista na Figura 29. O WRF e GDPS possuem velocidade em 120,0 m de altura, já o GFS em 100,0 m. Ao longo da série temporal notam-se eventos abruptos de alteração na velocidade do vento com picos extremos de velocidade, sendo o maior próximo de 25,00 m/s. As métricas da velocidade prevista por cada modelo NWP encontram-se na Tabela 11. Todos os modelos apresentaram RMSE acima de 2,50 m/s. O modelo com as melhores métricas foi o GDPS com 2,52 m/s de RMSE, -0,24 m/s de viés e r de 0,62. Em MIR-2, o WRF apresentou os piores valores de erro, sendo a grade d02 a pior com RMSE de 2,88 m/s, viés de -0,50 m/s e r de 0,53. Esse

resultado indica que a grade aninhada, d02, não resulta em um melhor resultado. O GFS, com velocidade em 100 m de altura, forneceu um RMSE de 2,56 m/s, viés de 0,26 m/s e r de 0,57, que são resultados próximos do GDPS.

Figura 29 - Série temporal da velocidade do vento medida, em médias de dez minutos, e da prevista pelos diferentes modelos NWP para o parque de Aura Mirim II.

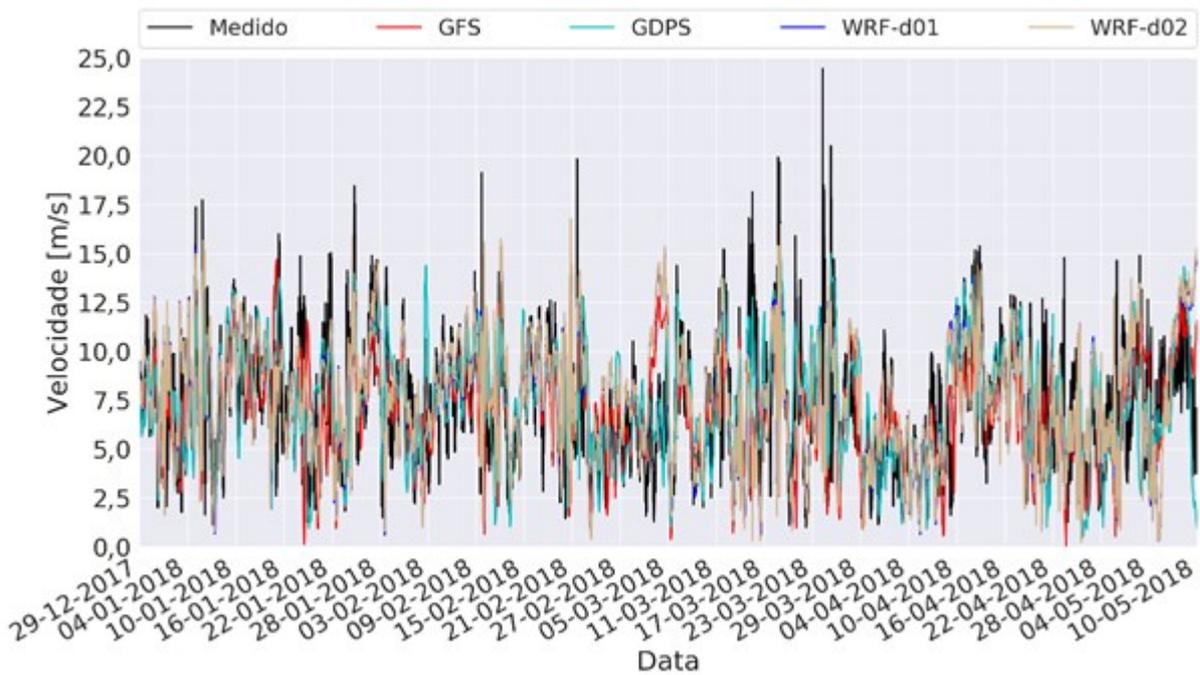


Tabela 11 - Métricas de erro para previsão de velocidade pelos modelos NWP para o parque de Aura Mirim II.

Modelo	RMSE [m/s]	viés [m/s]	NRMSE [%]	NMB [%]	r
GFS	2,56	0,26	35,5	3,7	0,57
GDPS	2,52	-0,24	35,0	-3,3	0,62
WRF-d01	2,83	-0,45	39,3	-6,3	0,54
WRF-d02	2,88	-0,50	40,0	-7,0	0,53

A velocidade do vento para o parque Ventos do Sertão, localizado no interior da Bahia, foi prevista melhor pelo modelo de mesoescala WRF com a grade d01. Isso pode ser resultado de o modelo levar em consideração as características físicas do terreno local, que é considerado complexo devido ao relevo, e parametrizações físicas que representam bem a atmosfera local. Já no parque Aura Mirim II, em um terreno simples no litoral do extremo Sul do Rio Grande do Sul, o modelo global GDPS forneceu os melhores resultados em todas as métricas de erro. Os maiores erros indicam maior dificuldade de previsão da velocidade do vento para o parque

MIR-2, isso se deve aos constantes eventos abruptos de mudança de velocidade, como visto na Figura 29. Outro possível fator é a influência da esteira dos demais aerogeradores no CESVP.

#### 4.2.2 Previsão de geração do parque eólico pelo esquema 1

A geração do parque Ventos do Sertão assim como as previsões de geração pelo método físico com os diversos modelos NWP são mostrados na Figura 30. Nesta subseção, o NRMSE e NMB são normalizados em relação à potência nominal do parque que é 30 MW. Os resultados das métricas de performance de cada previsão com o método físico, esquema 1, para o parque SER podem ser vistos na Tabela 12. O modelo de mesoescala WRF na grade d01 (WRF-d01) conseguiu maior acurácia pelo método físico, pois atingiu um NRMSE de 21,8 %, um NMB de -3,7 % e coeficiente de correlação de Pearson de 0,71. A grade d02 do WRF (WRF-d02) teve um resultado próximo, com NRMSE de 22,7 %, NMB de -2,6 % e r de 0,67. O GFS apresentou um NRMSE de 24,4 % e o GDPS de 28,7 % e em ambos o NMB foi acima de 9,0 %. O WRF subestima enquanto os modelos globais superestimam a geração do parque pelo método físico em SER, conforme os valores de NMB.

Figura 30 - Série temporal da geração medida e da prevista pelo método físico, esquema 1, com os diferentes modelos NWP para o parque eólico Ventos do Sertão.

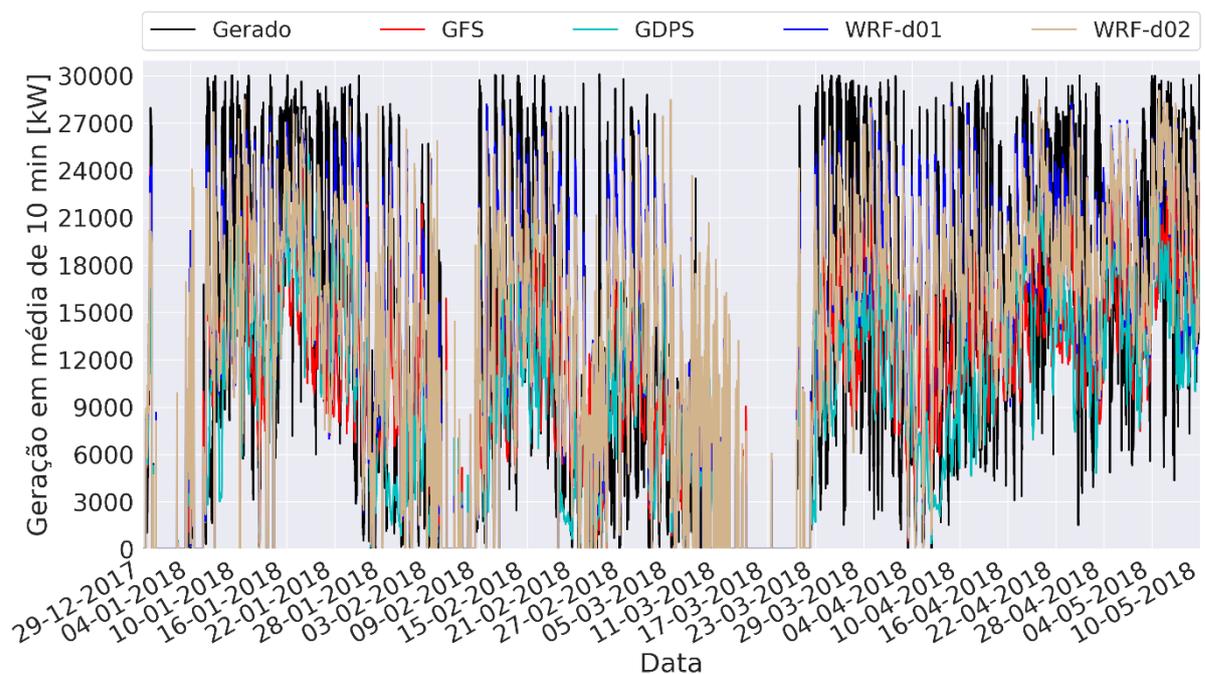
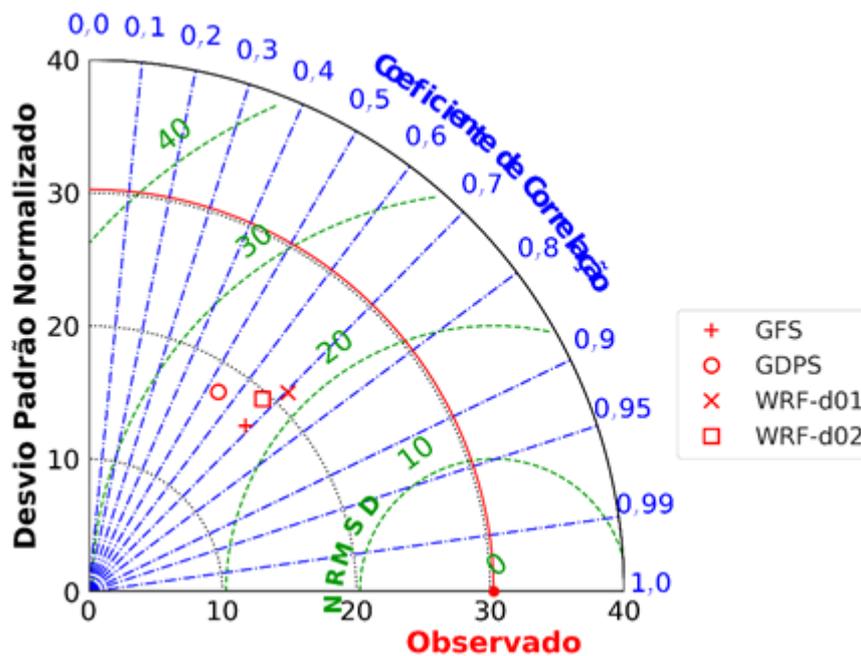


Tabela 12 - Métricas de erro para previsão de geração do parque eólico Ventos do Sertão pelo esquema 1, com o método físico.

Modelo	RMSE [kW]	viés [kW]	NRMSE [%]	NMB [%]	r
GFS	7327	2951	24,4	9,8	0,68
GDPS	8608	3946	28,7	13,2	0,54
WRF-d01	6530	-1105	21,8	-3,7	0,71
WRF-d02	6811	-785	22,7	-2,6	0,67

O diagrama de Taylor mostrado na Figura 31 comprova que o modelo de mesoescala WRF na grade d01 pelo esquema 1, com o método físico, representou de forma mais próxima da realidade os dados reais medidos em Ventos do Sertão. Isto pode ser afirmado uma vez que foi este o modelo com menor distância do ponto observado. Observa-se que o WRF-d01 apresenta o maior coeficiente de correlação de Pearson, o menor NRMSD e o desvio padrão normalizado mais próximo dos dados reais.

Figura 31 - Representação das séries temporais da previsão de geração do parque eólico Ventos do Sertão pelo esquema 1, com o método físico, em um diagrama de Taylor.



A série temporal da geração do parque Aura Mirim II e das previsões de geração pelo esquema 1, método físico, para os diferentes modelos de previsão numérica do tempo encontram-se na Figura 32. Na Tabela 13, encontram-se as métricas de erro para as previsões pelo

esquema 1 para MIR-2. Observe que todos os modelos globais conseguiram melhores resultados do que as duas grades do WRF, as mesmas conseguiram um NRMSE e NMB superior a 32,0 % e 13,0 %, respectivamente. A previsão pelo método físico com o GFS conseguiu o melhor desempenho dentre os modelos no esquema 1 para o parque Aura Mirim II, com um NRMSE de 27,5 %, NMB de -7,5 % e  $r$  de 0,62. Todos os modelos subestimaram a geração do parque, pois todos os valores de NMB foram negativos.

Figura 32 - Série temporal da geração medida e da prevista pelo método físico, esquema 1, com os diferentes modelos NWP para o parque eólico de Aura Mirim II.

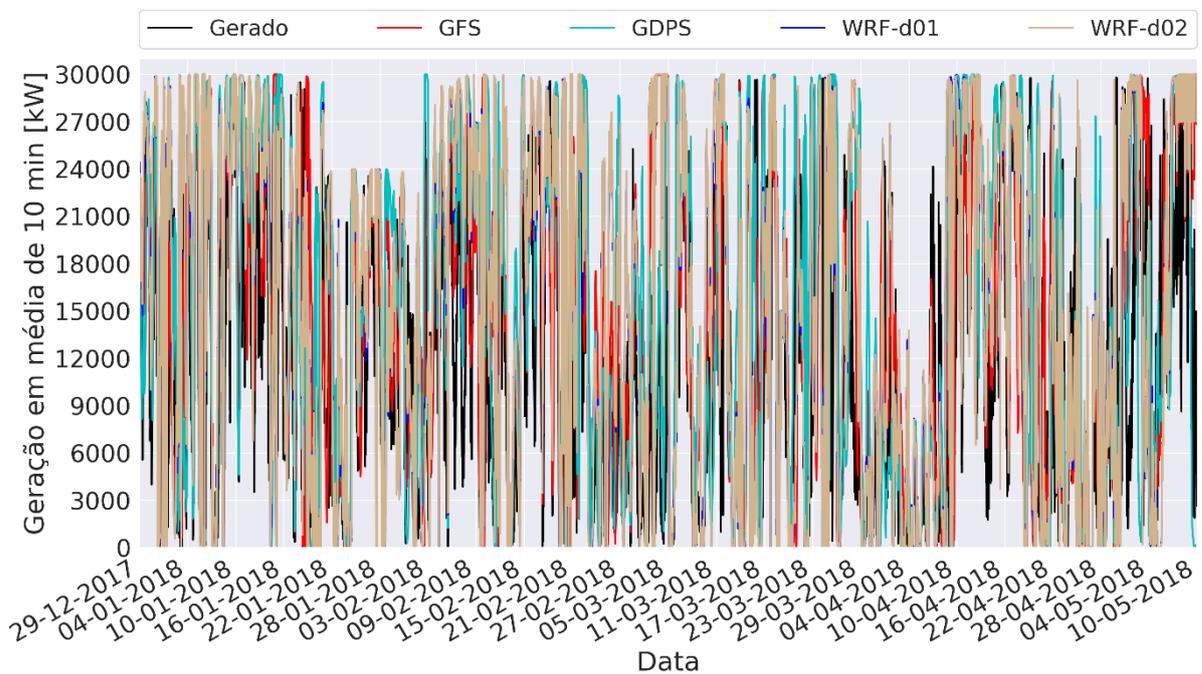


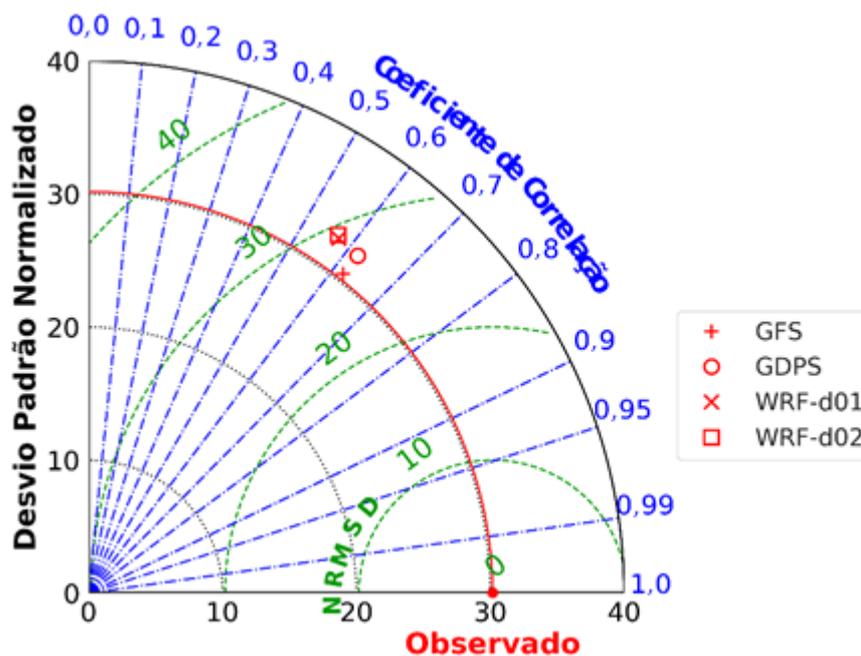
Tabela 13 - Métricas de erro para previsão de geração do parque eólico de Aura Mirim II pelo esquema 1, com o método físico.

Modelo	RMSE [kW]	viés [kW]	NRMSE [%]	NMB [%]	$r$
GFS	8257	-2251	27,5	-7,5	0,62
GDPS	8928	-3555	29,8	-11,9	0,62
WRF-d01	9603	-4040	32,0	-13,5	0,57
WRF-d02	9720	-4149	32,4	-13,8	0,57

A Figura 33 mostra o diagrama de Taylor que contém as estatísticas das séries temporais previstas pelos diferentes modelos NWP, no esquema 1, para o parque Aura Mirim II.

Como pode ser observado, o WRF-d01 e o WRF-d02 apresentam desempenhos similares e são os piores dentre os demais. O GDPS e GFS apresentam coeficiente de correlação de 0,62, entretanto, o GFS possui o desvio padrão normalizado mais próximo dos dados reais. O menor NRMSD também é obtido pela previsão de geração, no esquema 1, com o GFS. Por ser o ponto mais próximo do ponto observado, a previsão de geração com o modelo GFS é a representação mais próxima dos dados de geração do parque MIR-2 quando utilizado no método físico

Figura 33 - Representação das séries temporais da previsão de geração do parque eólico Aura Mirim II pelo esquema 1, com o método físico, em um diagrama de Taylor.



Em relação à previsão da geração do parque pelo método físico, esquema 1, o melhor resultado foi obtido pelo WRF-d01 para o parque Ventos do Sertão e pelo GFS para o parque Aura Mirim II. O WRF-d01 foi o melhor tanto para a previsão da velocidade quanto para a previsão de geração no parque SER, já para o parque MIR-2, o GDPS previu melhor a velocidade do vento enquanto o GFS a geração do parque.

#### 4.3 PREVISÃO DE GERAÇÃO PELOS MÉTODOS COM MACHINE LEARNING

Esta seção mostra o resultado dos esquemas 2, 3 e 4, os quais utilizam os métodos que preveem a geração eólica do parque com *machine learning*. A subseção 4.3.1 tratará do método que utiliza redes neurais artificiais para prever a velocidade do vento na posição da torre de

referência do parque e altura do cubo; a subseção 4.3.2 abrange o método que prevê a geração do aerogerador equivalente médio diretamente pelas redes neurais. Os códigos nas tabelas que mostram os resultados do RMSE médio da validação cruzada são “Número de Camadas-Esquema-Conjunto de Variáveis”, por exemplo, MLP2-Esq\_2-GFS-B indica uma rede neural com duas camadas escondidas, no esquema 2, com o conjunto de variáveis de entrada B do modelo GFS.

#### 4.3.1 Previsão com redes neurais artificiais da velocidade do vento

O resultado do RMSE médio obtido da validação cruzada para a velocidade do vento nos esquemas 2, 3 e 4 com as diversas topologias de redes encontram-se nas tabelas 14 a 18, para o parque Ventos do Sertão; e nas tabelas 22 a 27 para o parque Aura Mirim II. É importante observar que, em alguns casos, o aumento do número de neurônios em cada camada escondida não resulta em um menor RMSE. Isto é ocasionado pelo *overfitting*, que ocorre quando a rede neural consegue prever bem os dados do treinamento, porém não conseguem generalizar para dados que nunca entraram em contato com as mesmas.

##### Parque Eólico Ventos do Sertão

Os resultados de RMSE médio para o esquema 2 que utiliza o método que prevê a velocidade do vento para o parque eólico Ventos do Sertão (SER) com redes neurais e variáveis de entrada do modelo GFS encontram-se na Tabela 14. As figuras 34, 35 e 36 representam graficamente os resultados desta tabela e servem como exemplos de visualização para as demais tabelas do parque SER nesta subseção. As redes neurais com uma camada escondida obtiveram resultados similares, havendo destaque para a rede neural com o conjunto de variáveis H (MLP1-Esq\_2-GFS-H) e um neurônio na camada escondida que resultou em um RMSE médio de 1,56 m/s. Para a rede com duas camadas escondidas, o melhor resultado ocorreu com o conjunto de variáveis B (MLP2-Esq\_2-GFS-B) e dez neurônios por camada escondida com um RMSE médio de 1,62 m/s. E no caso de três camadas escondidas o melhor RMSE médio foi de 1,64 m/s, que se repetiu para o conjunto de variáveis B com cinco e dez neurônios, E com cinco



Figura 36 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq\_2) com os diferentes grupos de variáveis do GFS e redes neurais com três camadas escondidas (MLP3) que prevêem a velocidade do vento na altura do cubo para a torre de referência do parque Ventos do Sertão.

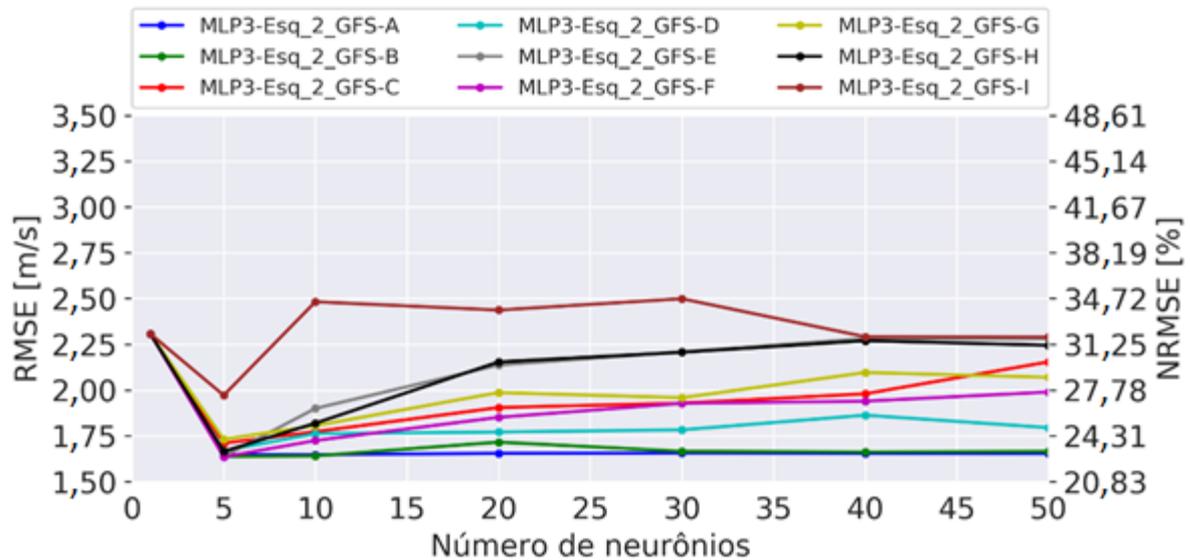


Tabela 14 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que preveem a velocidade do vento no esquema 2 (Esq\_2) com variáveis do GFS para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [m/s]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-GFS-A	1,67	1,67	1,65	1,68	1,66	1,65	1,65
MLP1-Esq_2-GFS-B	1,64	1,65	1,65	1,63	1,63	1,62	1,61
MLP1-Esq_2-GFS-C	1,66	1,69	1,66	1,69	1,69	1,70	1,75
MLP1-Esq_2-GFS-D	1,70	1,65	1,64	1,62	1,64	1,65	1,66
MLP1-Esq_2-GFS-E	1,60	1,60	1,66	1,73	1,81	1,88	1,87
MLP1-Esq_2-GFS-F	1,61	1,64	1,63	1,59	1,62	1,63	1,65
MLP1-Esq_2-GFS-G	1,61	1,59	1,64	1,59	1,68	1,66	1,70
MLP1-Esq_2-GFS-H	1,56	1,63	1,66	1,71	1,85	1,92	1,91
MLP1-Esq_2-GFS-I	1,64	1,95	2,23	2,40	2,41	2,41	2,47
MLP2-Esq_2-GFS-A	2,31	1,64	1,66	1,64	1,64	1,65	1,66
MLP2-Esq_2-GFS-B	2,31	1,63	1,62	1,66	1,63	1,66	1,66
MLP2-Esq_2-GFS-C	2,31	1,67	1,73	1,85	1,83	1,89	1,93
MLP2-Esq_2-GFS-D	2,31	1,74	1,79	1,80	1,77	1,81	1,79
MLP2-Esq_2-GFS-E	2,31	1,73	1,82	2,01	2,23	2,07	2,18
MLP2-Esq_2-GFS-F	2,31	1,66	1,73	1,78	1,75	1,78	1,94
MLP2-Esq_2-GFS-G	2,31	1,68	1,77	1,88	1,83	1,82	1,89
MLP2-Esq_2-GFS-H	2,31	1,65	1,84	2,04	2,10	2,28	2,28
MLP2-Esq_2-GFS-I	2,31	2,32	2,27	2,81	2,83	2,53	2,57
MLP3-Esq_2-GFS-A	2,31	1,65	1,65	1,65	1,66	1,65	1,65
MLP3-Esq_2-GFS-B	2,31	1,64	1,64	1,72	1,67	1,66	1,66

MLP3-Esq_2-GFS-C	2,31	1,71	1,77	1,90	1,93	1,98	2,15
MLP3-Esq_2-GFS-D	2,31	1,67	1,76	1,77	1,78	1,86	1,79
MLP3-Esq_2-GFS-E	2,31	1,64	1,90	2,14	2,21	2,28	2,28
MLP3-Esq_2-GFS-F	2,31	1,64	1,72	1,85	1,93	1,94	1,99
MLP3-Esq_2-GFS-G	2,31	1,73	1,81	1,99	1,96	2,10	2,07
MLP3-Esq_2-GFS-H	2,31	1,66	1,82	2,15	2,21	2,27	2,24
MLP3-Esq_2-GFS-I	2,31	1,97	2,48	2,44	2,50	2,29	2,29

A Tabela 15 apresenta os resultados do RMSE médio obtidos pela validação cruzada para as diferentes topologias de redes neurais que preveem a velocidade do vento para o parque SER no esquema 2 e diferentes conjuntos de variáveis de entrada do modelo GDPS. O conjunto de variáveis para as redes neurais com uma camada escondida que obteve o melhor resultado foi o G (MLP1-Esq\_2-GDPS-G), com dez neurônios, com um RMSE médio de 1,71 m/s. Nos testes com as redes neurais de duas camadas escondidas, o melhor RMSE médio foi também de 1,71 m/s e aconteceu com o conjunto de variáveis F (MLP2-Esq\_2-GDPS-F) e cinco neurônios por camada escondida. O menor RMSE médio nas redes neurais com três camadas escondidas foi de 1,69 m/s para o conjunto de variáveis F (MLP3-Esq\_2-GDPS-F) com cinco neurônios por camada escondida.

Tabela 15 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que preveem a velocidade do vento no esquema 2 (Esq\_2) com variáveis do GDPS para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [m/s]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-GDPS-A	1,93	1,88	1,90	1,88	1,88	1,87	1,90
MLP1-Esq_2-GDPS-B	1,88	1,87	1,86	1,85	1,79	1,77	1,77
MLP1-Esq_2-GDPS-C	1,92	1,88	1,85	1,85	1,82	1,85	1,86
MLP1-Esq_2-GDPS-D	1,94	1,85	1,96	1,93	1,92	1,99	2,03
MLP1-Esq_2-GDPS-E	1,82	1,89	1,89	2,02	2,20	2,18	2,27
MLP1-Esq_2-GDPS-F	1,88	1,92	1,85	1,82	1,85	1,84	1,87
MLP1-Esq_2-GDPS-G	1,82	1,80	1,71	1,88	1,88	1,93	1,96
MLP1-Esq_2-GDPS-H	1,80	1,85	1,89	1,93	2,07	2,19	2,24
MLP1-Esq_2-GDPS-I	1,77	2,06	2,26	2,54	2,76	2,70	2,65
MLP2-Esq_2-GDPS-A	2,31	1,88	1,87	1,87	1,88	1,86	1,87
MLP2-Esq_2-GDPS-B	2,31	1,77	1,79	1,83	1,81	1,83	1,86
MLP2-Esq_2-GDPS-C	2,31	1,81	1,86	1,94	2,00	2,03	2,10
MLP2-Esq_2-GDPS-D	2,31	2,14	2,15	2,56	2,46	2,44	2,49
MLP2-Esq_2-GDPS-E	2,31	2,36	2,67	3,56	3,52	3,53	3,66
MLP2-Esq_2-GDPS-F	2,31	1,71	1,79	1,85	1,94	1,93	1,95
MLP2-Esq_2-GDPS-G	2,31	1,74	1,90	2,03	2,11	2,27	2,32
MLP2-Esq_2-GDPS-H	2,31	1,87	1,88	2,11	2,37	2,63	2,54
MLP2-Esq_2-GDPS-I	2,31	2,27	2,48	2,64	2,78	2,78	2,64

MLP3-Esq_2-GDPS-A	2,31	1,86	1,87	1,87	1,86	1,90	1,89
MLP3-Esq_2-GDPS-B	2,31	1,81	1,80	1,91	1,88	1,93	1,99
MLP3-Esq_2-GDPS-C	2,31	1,85	1,91	2,10	2,14	2,11	2,20
MLP3-Esq_2-GDPS-D	2,31	2,11	2,00	2,48	2,24	2,50	2,57
MLP3-Esq_2-GDPS-E	2,31	1,96	2,51	3,79	3,15	3,65	3,43
MLP3-Esq_2-GDPS-F	2,31	1,69	1,85	1,89	2,00	2,21	2,22
MLP3-Esq_2-GDPS-G	2,31	1,77	2,00	2,31	2,37	2,24	2,27
MLP3-Esq_2-GDPS-H	2,31	1,92	2,11	2,35	2,59	2,52	2,40
MLP3-Esq_2-GDPS-I	2,31	2,24	2,48	2,59	2,55	2,43	2,51

Os resultados de RMSE médio dos testes na validação cruzada das redes neurais que prevêem a velocidade do vento para o parque Ventos do Sertão com variáveis de entrada do modelo WRF, na grade d01, estão na Tabela 16. O valor do RMSE médio 1,62 m/s foi o menor dentre todos os casos para a topologia com uma camada escondida, o qual ocorreu com o conjunto de variáveis F (MLP1-Esq\_2-WRF-d01-F) e um neurônio. Nas redes neurais com duas camadas escondidas, o melhor RMSE médio foi de 1,63 m/s no conjunto de variáveis de entrada H (MLP2-Esq\_2-WRF-d01-H) e um neurônio por camada escondida. O conjunto de variáveis E com cinco neurônios por camada escondida e o conjunto H com um neurônio por camada escondida obtiveram o menor RMSE médio dentre as redes com três camadas escondidas, que foi de 1,65 m/s. Entretanto, o conjunto de variáveis E (MLP3-Esq\_2-WRF-d01-E) com cinco neurônios apresentou um desvio padrão menor, igual a 0,30 m/s.

Tabela 16 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêem a velocidade do vento no esquema 2 (Esq\_2) com variáveis do WRF-d01 para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [m/s]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-WRF-d01-A	1,71	1,7	1,69	1,7	1,7	1,7	1,7
MLP1-Esq_2-WRF-d01-B	1,71	1,71	1,71	1,71	1,7	1,71	1,7
MLP1-Esq_2-WRF-d01-C	1,72	1,76	1,75	1,79	1,8	1,81	1,82
MLP1-Esq_2-WRF-d01-D	1,69	1,65	1,65	1,65	1,64	1,64	1,67
MLP1-Esq_2-WRF-d01-E	1,65	1,7	1,75	1,77	1,82	1,87	1,85
MLP1-Esq_2-WRF-d01-F	1,62	1,65	1,64	1,64	1,66	1,68	1,69
MLP1-Esq_2-WRF-d01-G	1,63	1,63	1,64	1,65	1,68	1,73	1,73
MLP1-Esq_2-WRF-d01-H	1,67	1,76	1,82	1,95	2,08	2,04	2,1
MLP1-Esq_2-WRF-d01-I	1,71	2,02	2,2	2,24	2,34	2,3	2,39
MLP2-Esq_2-WRF-d01-A	2,31	1,69	1,71	1,70	1,69	1,70	1,69
MLP2-Esq_2-WRF-d01-B	2,31	1,71	1,76	1,75	1,77	1,78	1,78
MLP2-Esq_2-WRF-d01-C	2,31	1,78	1,87	1,92	1,93	1,93	1,96

MLP2-Esq_2-WRF-d01-D	2,31	1,88	2,01	2,07	2,02	2,03	2,00
MLP2-Esq_2-WRF-d01-E	2,31	1,81	2,10	1,90	2,13	2,03	2,06
MLP2-Esq_2-WRF-d01-F	2,31	1,66	1,73	1,76	1,76	1,78	1,79
MLP2-Esq_2-WRF-d01-G	2,31	1,68	1,73	1,78	1,87	1,92	1,91
MLP2-Esq_2-WRF-d01-H	1,63	1,76	1,93	2,10	2,08	2,15	2,05
MLP2-Esq_2-WRF-d01-I	2,31	1,91	2,08	2,25	2,28	2,31	2,32
MLP3-Esq_2-WRF-d01-A	2,31	1,70	1,71	1,69	1,72	1,72	1,72
MLP3-Esq_2-WRF-d01-B	2,31	1,75	1,77	1,77	1,80	1,85	1,82
MLP3-Esq_2-WRF-d01-C	2,31	1,80	1,88	1,93	2,03	2,06	2,08
MLP3-Esq_2-WRF-d01-D	2,31	1,91	1,94	2,07	2,03	2,22	1,96
MLP3-Esq_2-WRF-d01-E	2,31	1,65	2,02	2,11	2,15	2,21	2,43
MLP3-Esq_2-WRF-d01-F	2,31	1,68	1,75	1,84	1,90	1,95	2,01
MLP3-Esq_2-WRF-d01-G	2,31	1,71	1,81	1,91	1,99	2,06	2,12
MLP3-Esq_2-WRF-d01-H	1,65	1,78	1,96	2,09	2,11	2,09	2,10
MLP3-Esq_2-WRF-d01-I	2,31	1,94	2,20	2,30	2,24	2,18	2,18

Na Tabela 17, encontram-se os resultados do esquema 2 utilizando as redes neurais para prever a velocidade do vento para SER com variáveis de entrada da grade d02 do WRF. No conjunto de variáveis de entrada testadas para a rede com uma camada escondida, o F (MLP1-Esq\_2-WRF-d02-F) com um neurônio obteve o melhor valor de RMSE médio que foi de 1,62 m/s. No caso das redes com duas camadas escondidas, o conjunto H (MLP2-Esq\_2-WRF-d02-H) e um neurônio por camada escondida alcançou 1,63 m/s de RMSE médio, o qual foi o melhor para esta topologia. O grupo de variáveis H também apresentou o melhor resultado de RMSE médio dentre as redes com três camadas escondidas (MLP3-Esq\_2-WRF-d02-H) com um neurônio por camada, o qual foi de 1,64 m/s.

Tabela 17 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêem a velocidade do vento no esquema 2 (Esq\_2) com variáveis do WRF-d02 para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [m/s]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-WRF-d02-A	1,76	1,76	1,76	1,76	1,76	1,77	1,77
MLP1-Esq_2-WRF-d02-B	1,76	1,75	1,75	1,76	1,75	1,77	1,76
MLP1-Esq_2-WRF-d02-C	1,78	1,80	1,81	1,83	1,85	1,87	1,88
MLP1-Esq_2-WRF-d02-D	1,71	1,66	1,65	1,64	1,65	1,67	1,65
MLP1-Esq_2-WRF-d02-E	1,67	1,70	1,74	1,79	1,80	1,78	1,85
MLP1-Esq_2-WRF-d02-F	1,62	1,64	1,66	1,67	1,68	1,66	1,68
MLP1-Esq_2-WRF-d02-G	1,64	1,65	1,67	1,69	1,72	1,72	1,72
MLP1-Esq_2-WRF-d02-H	1,68	1,78	1,81	1,94	2,00	2,06	2,10
MLP1-Esq_2-WRF-d02-I	1,72	2,02	2,10	2,21	2,27	2,31	2,34
MLP2-Esq_2-WRF-d02-A	2,31	1,75	1,75	1,77	1,75	1,76	1,78
MLP2-Esq_2-WRF-d02-B	2,31	1,76	1,80	1,83	1,84	1,84	1,85
MLP2-Esq_2-WRF-d02-C	2,31	1,82	1,86	1,96	2,01	2,01	2,04

MLP2-Esq_2-WRF-d02-D	2,31	1,74	1,87	1,82	1,93	2,00	1,90
MLP2-Esq_2-WRF-d02-E	2,31	1,77	1,82	1,97	1,97	2,13	2,06
MLP2-Esq_2-WRF-d02-F	2,31	1,67	1,70	1,74	1,79	1,80	1,82
MLP2-Esq_2-WRF-d02-G	2,31	1,68	1,73	1,77	1,87	1,86	1,85
MLP2-Esq_2-WRF-d02-H	1,63	1,78	1,91	2,01	2,15	2,19	2,18
MLP2-Esq_2-WRF-d02-I	2,31	1,88	2,03	2,41	2,24	2,24	2,35
MLP3-Esq_2-WRF-d02-A	2,31	1,76	1,78	1,78	1,75	1,78	1,76
MLP3-Esq_2-WRF-d02-B	2,31	1,80	1,82	1,83	1,85	1,87	1,88
MLP3-Esq_2-WRF-d02-C	2,31	1,86	1,93	2,00	2,08	2,12	2,13
MLP3-Esq_2-WRF-d02-D	2,31	1,85	1,96	1,96	2,03	1,87	1,95
MLP3-Esq_2-WRF-d02-E	2,31	1,70	2,00	2,05	2,22	2,15	2,24
MLP3-Esq_2-WRF-d02-F	2,31	1,72	1,77	1,81	1,89	1,90	1,93
MLP3-Esq_2-WRF-d02-G	2,31	1,69	1,80	1,87	1,93	2,02	2,07
MLP3-Esq_2-WRF-d02-H	1,64	1,80	1,91	2,05	2,10	2,18	2,08
MLP3-Esq_2-WRF-d02-I	2,31	1,91	2,07	2,18	2,28	2,27	2,16

Os resultados da validação cruzada empregando o esquema 3, com variáveis de entrada do GFS e GDPS, com as redes neurais artificiais prevendo a velocidade do vento para o parque Ventos do Sertão são mostrados na Tabela 18. O RMSE médio de 1,62 m/s se repetiu nos testes com redes neurais com uma camada escondida para o conjunto de variáveis B, com cinco neurônios, E, com um neurônio e G, com cinco neurônios. Porém, o grupo de variáveis B (MLP1-Esq\_3-B), com cinco neurônios apresentou o menor desvio padrão, com o valor de 0,29 m/s. As redes neurais com duas camadas escondidas tiveram o melhor resultado de RMSE médio com o conjunto B (MLP2-Esq\_3-B) e cinco neurônios por camada escondida, o qual foi de 1,59 m/s. O grupo B também foi o que resultou no menor RMSE médio para as redes neurais com três camadas escondidas (MLP3-Esq\_3-B), com valor de 1,59 m/s que foi obtido na rede neural com cinco neurônios por camada escondida. Apesar dos melhores resultados das topologias de duas e três camadas escondidas apresentarem o mesmo valor de RMSE médio, a topologia com duas camadas escondidas apresentou o menor desvio padrão do RMSE médio que foi de 0,25 m/s.

Tabela 18 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a velocidade do vento no esquema 3 (Esq\_3) com variáveis do GFS e GDPS para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [m/s]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_3-A	1,66	1,65	1,63	1,65	1,65	1,64	1,65
MLP1-Esq_3-B	1,64	1,62	1,65	1,64	1,63	1,63	1,64

MLP1-Esq_3-C	1,66	1,66	1,67	1,72	1,73	1,76	1,76
MLP1-Esq_3-D	1,69	1,67	1,64	1,70	1,75	1,77	1,82
MLP1-Esq_3-E	1,62	1,77	1,95	2,05	2,29	2,32	2,31
MLP1-Esq_3-F	1,68	1,66	1,68	1,74	1,77	1,81	1,82
MLP1-Esq_3-G	1,64	1,62	1,69	1,91	1,91	1,96	2,12
MLP1-Esq_3-H	1,64	1,76	1,84	2,08	2,18	2,24	2,27
MLP1-Esq_3-I	1,76	2,00	2,24	2,31	2,35	2,41	2,52
MLP2-Esq_3-A	2,31	1,61	1,64	1,64	1,66	1,70	1,67
MLP2-Esq_3-B	2,31	1,59	1,63	1,67	1,68	1,77	1,82
MLP2-Esq_3-C	2,31	1,60	1,69	1,89	1,95	1,95	2,00
MLP2-Esq_3-D	2,31	1,94	2,28	2,77	2,63	2,47	2,39
MLP2-Esq_3-E	2,31	2,42	2,57	3,11	2,61	2,73	3,10
MLP2-Esq_3-F	2,31	1,65	1,77	1,97	2,03	2,30	2,15
MLP2-Esq_3-G	2,31	1,71	1,93	2,12	2,25	2,12	2,22
MLP2-Esq_3-H	2,31	1,78	1,94	2,20	2,49	2,47	2,62
MLP2-Esq_3-I	2,31	2,08	2,12	2,41	2,20	2,07	2,14
MLP3-Esq_3-A	2,31	1,63	1,65	1,69	1,72	1,76	1,76
MLP3-Esq_3-B	2,31	1,59	1,67	1,78	1,89	1,96	1,98
MLP3-Esq_3-C	2,31	1,70	1,88	2,09	2,06	2,08	2,10
MLP3-Esq_3-D	2,31	1,93	2,04	2,24	2,99	2,91	2,84
MLP3-Esq_3-E	2,31	2,13	2,06	2,87	2,93	3,36	3,22
MLP3-Esq_3-F	2,31	1,69	1,85	2,07	2,07	2,21	2,17
MLP3-Esq_3-G	2,31	1,71	1,90	2,14	2,19	2,30	2,26
MLP3-Esq_3-H	2,31	1,84	2,06	2,26	2,38	2,30	2,31
MLP3-Esq_3-I	2,31	1,97	2,02	2,23	2,21	2,21	2,05

As variáveis de entrada do GFS, GDPS e WRF-d01 são utilizadas no esquema 4 e os resultados da validação cruzada para este esquema com as redes neurais que prevêem a velocidade do vento para o parque SER encontram-se na Tabela 19. O menor valor de RMSE médio para as redes neurais com uma camada foi 1,60 m/s e aconteceu com o conjunto de variáveis A (MLP1-Esq\_4-A) com um e cinco neurônios escondidos, entretanto, o menor desvio padrão foi de 0,30 m/s e ocorreu com a rede que possui cinco neurônios na camada escondida. Na topologia com duas camadas escondidas, o melhor RMSE médio foi de 1,59 m/s e ocorreu em redes com cinco neurônios por camada escondida nos grupos de variáveis de entrada A, B e C, porém o menor desvio padrão ocorreu no conjunto B (MLP2-Esq\_4-B) e foi de 0,26 m/s. Os testes com redes neurais com três camadas escondidas no esquema 4 que obtiveram menor RMSE médio ocorreram com o conjunto de variáveis B (MLP3-Esq\_4-B) e cinco neurônios por camada escondida, possuindo o valor de 1,62 m/s.

Tabela 19 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a velocidade do vento no esquema 4 (Esq\_4) com variáveis do GFS, GDPS e WRF-d01 para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [m/s]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_4-A	1.60	1.60	1.62	1.62	1.61	1.62	1.64
MLP1-Esq_4-B	1.61	1.63	1.64	1.67	1.65	1.64	1.67
MLP1-Esq_4-C	1.63	1.67	1.69	1.76	1.76	1.79	1.83
MLP1-Esq_4-D	1.62	1.69	1.68	1.76	1.83	1.80	1.86
MLP1-Esq_4-E	1.63	1.76	1.98	2.09	2.22	2.27	2.39
MLP1-Esq_4-F	1.64	1.62	1.69	1.83	1.86	1.91	1.96
MLP1-Esq_4-G	1.63	1.73	1.76	1.83	2.00	2.04	2.06
MLP1-Esq_4-H	1.68	1.92	1.97	2.12	2.16	2.23	2.27
MLP1-Esq_4-I	1.81	2.13	2.21	2.43	2.38	2.39	2.54
MLP2-Esq_4-A	2.31	1.59	1.66	1.72	1.76	1.78	1.85
MLP2-Esq_4-B	2.31	1.59	1.64	1.73	1.76	1.80	1.86
MLP2-Esq_4-C	2.31	1.59	1.76	1.81	1.90	1.98	1.95
MLP2-Esq_4-D	2.31	1.89	2.29	2.30	2.64	3.09	2.74
MLP2-Esq_4-E	2.31	2.21	3.10	2.79	3.24	3.05	3.22
MLP2-Esq_4-F	2.31	1.61	1.83	1.93	2.02	2.09	2.11
MLP2-Esq_4-G	2.31	1.77	1.90	2.17	2.12	2.21	2.23
MLP2-Esq_4-H	2.31	1.84	2.04	2.19	2.19	2.22	2.24
MLP2-Esq_4-I	2.31	2.00	2.17	2.16	2.26	2.11	2.16
MLP3-Esq_4-A	2.31	1.63	1.67	1.89	1.84	1.95	1.97
MLP3-Esq_4-B	2.31	1.62	1.73	1.82	1.89	2.00	1.96
MLP3-Esq_4-C	2.31	1.69	1.73	2.04	2.00	2.07	2.17
MLP3-Esq_4-D	2.31	1.99	2.49	2.72	2.84	3.40	2.96
MLP3-Esq_4-E	2.31	2.29	2.66	3.12	3.17	2.94	2.90
MLP3-Esq_4-F	2.31	1.67	1.81	2.03	2.13	2.19	2.17
MLP3-Esq_4-G	2.31	1.69	1.95	2.03	2.18	2.23	2.17
MLP3-Esq_4-H	2.31	1.83	2.02	2.19	2.21	2.15	2.21
MLP3-Esq_4-I	2.31	2.02	2.14	2.15	2.13	2.07	2.02

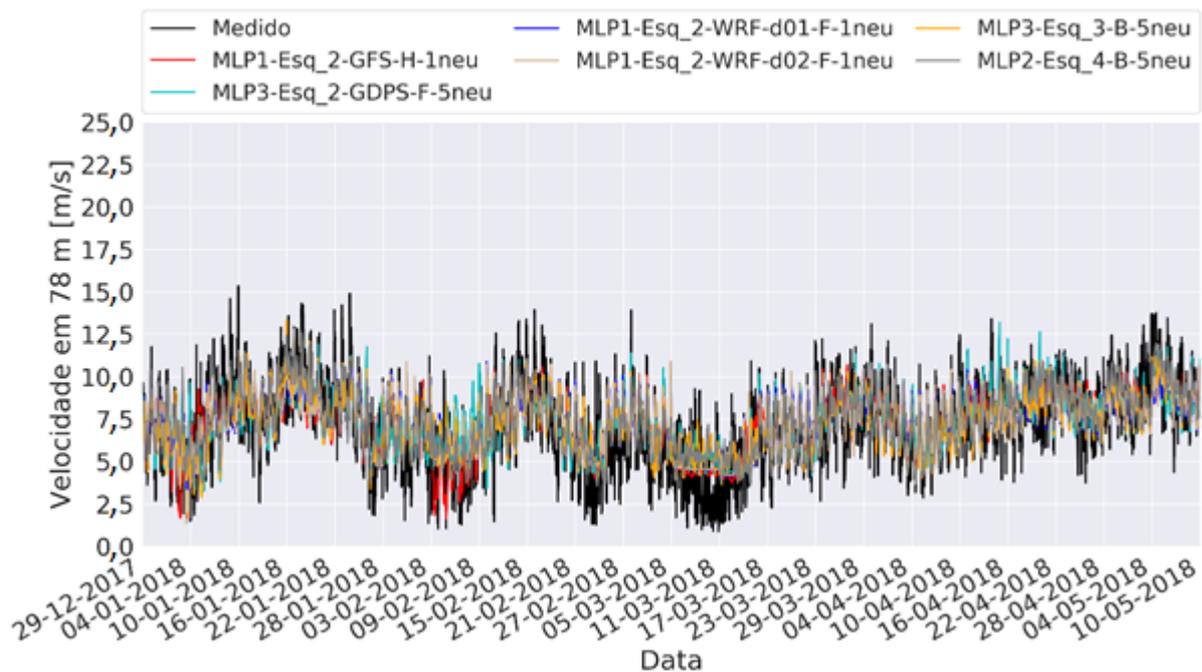
As melhores topologias das redes neurais que prevêm a velocidade do vento para o parque Ventos do Sertão, nos diferentes esquemas, estão listadas na Tabela 20, onde é possível verificar também o número de neurônios por camada escondida e o RMSE médio. O menor valor do RMSE médio foi de 1,56 m/s e ocorreu para o esquema 2 com o conjunto de variáveis H, uma camada escondida e um neurônio. O segundo menor valor foi de 1,59 m/s e ocorreu nos esquemas 3 e 4, os quais se utilizam de variáveis de mais de um modelo de previsão numérica do tempo.

Tabela 20 - Melhores topologias das redes neurais que preveem a velocidade do vento para os esquemas 2, 3 e 4 do parque Ventos do Sertão.

Código	Nº de neurônios por camada escondida	RMSE médio [m/s]
MLP1-Esq_2-GFS-H	1	1,56
MLP3-Esq_2-GDPS-F	5	1,69
MLP1-Esq_2-WRF-d01-F	1	1,62
MLP1-Esq_2-WRF-d02-F	1	1,62
MLP3-Esq_3-B	5	1,59
MLP2-Esq_4-B	5	1,59

A Figura 37 mostra as séries temporais da velocidade medida na torre de referência do parque Ventos do Sertão, na altura de 78,0 m, e da velocidade do vento prevista pelas melhores topologias dos esquemas 2, 3 e 4. Como se pode observar, entre os dias 05/03/2018 e 11/03/2018 as previsões ficaram distantes da medição na torre.

Figura 37 - Série temporal da velocidade do vento em médias de dez minutos medida e da prevista pelas melhores topologias das redes neurais dos esquemas 2, 3 e 4 para o Parque Ventos do Sertão, na altura de 78 m.



As métricas de erro para as séries de velocidade previstas, da Figura 37, encontram-se na Tabela 21. Observa-se que o RMSE de todos os esquemas listados ficaram melhores em relação à previsão direta pelos modelos NWP, que possuía o menor RMSE de 1,82 m/s e é

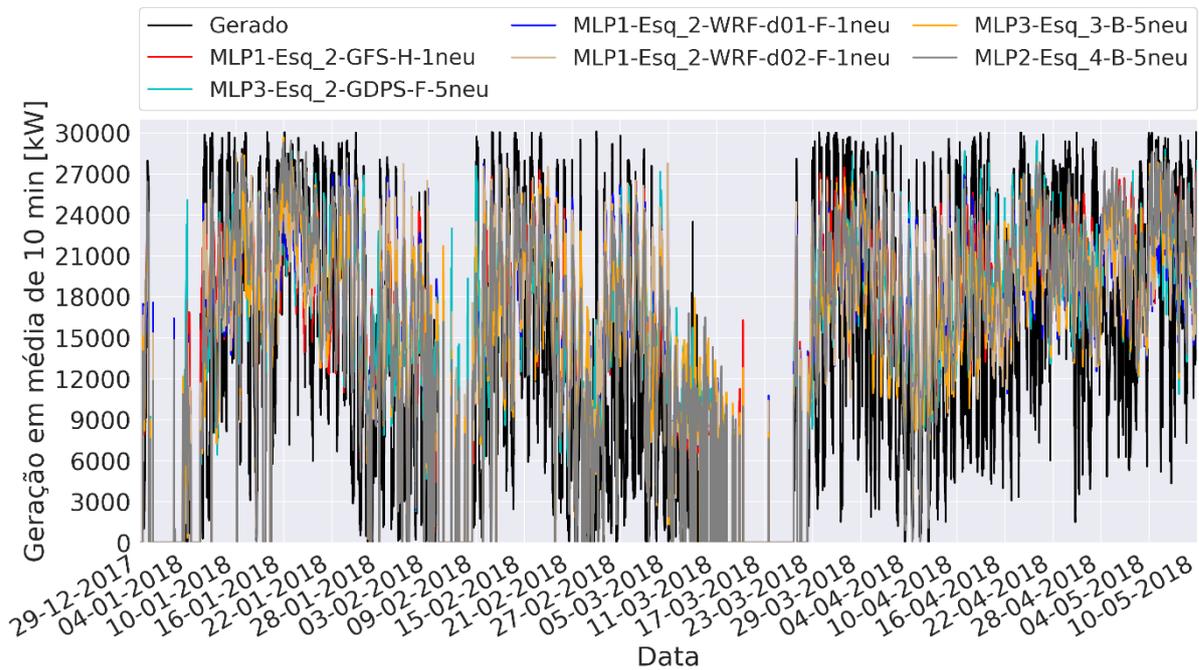
mostrado na Tabela 10. O valor negativo de viés indica que as previsões têm tendência de subestimar a velocidade do vento, porém os valores são próximos de zero. O melhor RMSE foi de 1,58 m/s e ocorreu para a série temporal resultante do esquema 2 que utiliza uma camada escondida com um neurônio e o conjunto de variáveis H do GFS (MLP1-Esq\_2-GFS-H-1neu). Este valor é 13,2 % menor que o melhor RMSE obtido por um modelo NWP, WRF-d01, para o parque SER. MLP1-Esq\_2-GFS-H-1neu apresentou um coeficiente de correlação de Pearson de 0,74, valor este 7,3 % maior que o do melhor modelo NWP, o WRF-d01. Os coeficientes de correlação melhoraram se comparados com o resultado obtido pelos modelos NWP, vistos na Tabela 10.

Tabela 21 - Métricas de erro para previsão da velocidade pelas redes neurais dos esquemas de previsão com *machine learning* para o parque Ventos do Sertão.

<b>Código</b>	<b>RMSE [m/s]</b>	<b>viés [m/s]</b>	<b>NRMSE [%]</b>	<b>NMB [%]</b>	<b>r</b>
MLP1-Esq_2-GFS-H-1neu	1,58	-0,23	21,9	-3,2	0,74
MLP3-Esq_2-GDPS-F-5neu	1,72	-0,20	23,9	-2,8	0,67
MLP1-Esq_2-WRF-d01-F-1neu	1,64	-0,23	22,8	-3,2	0,71
MLP1-Esq_2-WRF-d02-F-1neu	1,64	-0,26	22,7	-3,6	0,71
MLP3-Esq_3-B-5neu	1,62	-0,13	22,5	-1,9	0,72
MLP2-Esq_4-B-5neu	1,61	-0,24	22,3	-3,4	0,73

As séries temporais da geração real e previstas para o parque Ventos do Sertão pelas melhores topologias e conjuntos de variáveis dos esquemas 2, 3 e 4 são mostradas na Figura 38.

Figura 38 - Geração real do parque Ventos do Sertão e prevista pelo método com redes neurais que prevê a velocidade do vento com a melhor topologia e conjunto de variáveis de cada esquema de previsão.



As métricas de erro das previsões de geração do parque Ventos do Sertão pelas melhores topologias e grupos de variáveis dos esquemas que utilizam a velocidade do vento prevista pelas redes neurais, presentes na Figura 38, são apresentadas na Tabela 22. A diferença entre o pior e melhor resultado de NRMSE foi de 1,1 %, o que indica que os resultados de cada esquema foram próximos. O menor valor de NRMSE foi de 22,7 % para o esquema 3 com o conjunto de variáveis B em uma rede neural com três camadas escondidas e cinco neurônios por camada escondida (MLP3-Esq\_3-B-5neu), seguido do esquema 2 com uma rede neural de uma camada escondida e um neurônio com o grupo de variáveis de entrada H do GFS (MLP1-Esq\_2-GFS-H-1neu) que obteve um NRMSE de 22,8 %. O pior valor de NRMSE, 23,9 %, ocorreu com o esquema 2 com as variáveis de entrada do conjunto F do GDPS em uma rede neural com três camadas escondidas e cinco neurônios por camada escondida. Todos os esquemas subestimaram a geração do parque, visto que o NMB foi negativo para os mesmos. O menor NMB foi de -7,8 % para o MLP3-Esq\_3-B-5neu. Os coeficientes de correlação foram em sua maioria superiores a 0,70, e o melhor foi de 0,74 para o MLP1-Esq\_2-GFS-H-1neu.

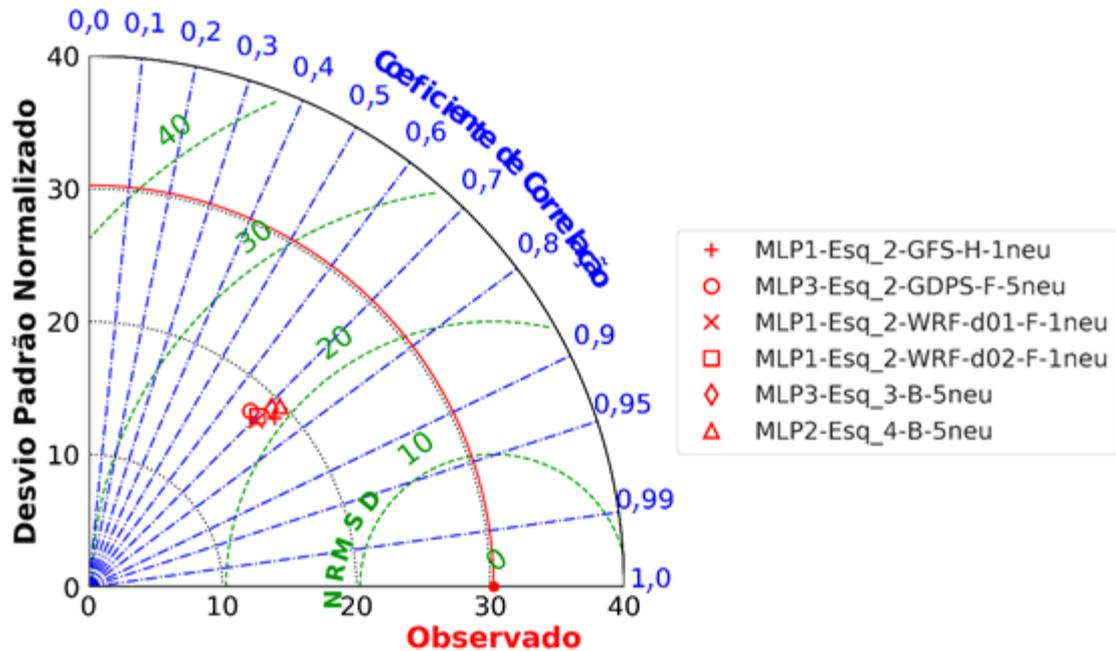
Tabela 22 - Métricas de erro das previsões de geração do parque Ventos do Sertão pelas melhores topologias e conjunto de variáveis dos esquemas que empregaram redes neurais na previsão da velocidade do vento.

Código	RMSE [kW]	viés [kW]	NRMSE [%]	NMB [%]	r
--------	--------------	--------------	--------------	------------	---

MLP1-Esq_2-GFS-H-1neu	6831	-2819	22,8	-9,4	0,74
MLP3-Esq_2-GDPS-F-5neu	7155	-2373	23,9	-7,9	0,67
MLP1-Esq_2-WRF-d01-F-1neu	7005	-2581	23,4	-8,6	0,71
MLP1-Esq_2-WRF-d02-F-1neu	7103	-2760	23,7	-9,2	0,70
MLP3-Esq_3-B-5neu	6818	-2348	22,7	-7,8	0,71
MLP2-Esq_4-B-5neu	6846	-2679	22,8	-8,9	0,72

Eleger o melhor esquema de previsão de geração, que utiliza o método com redes neurais para prever a velocidade do vento, para o parque Ventos do Sertão apenas com as métricas da Tabela 22 é difícil. Observa-se que os esquemas ficam muito próximos uns dos outros na representação estatística pelo diagrama de Taylor na Figura 39. Entretanto, o MLP1-Esq\_2-GFS-H-1neu foi o esquema com a menor distância do ponto observado, por isso denominou-se o mesmo como o esquema que melhor representa a previsão de geração do parque Ventos do Sertão com o método que utiliza redes neurais para prever a velocidade do vento. O esquema MLP2-Esq\_4-B-5neu seguido do MLP3-Esq\_3-B-5neu tiveram um bom desempenho, o que indica que os esquemas com mais de um modelo NWP prevêm bem a geração de energia do parque SER.

Figura 39 - Representação estatística da previsão de geração pelas melhores topologias e conjunto de variáveis dos esquemas de previsão que utilizam o método com *machine learning* que prevê a velocidade do vento com redes neurais artificiais para o parque Ventos do Sertão.



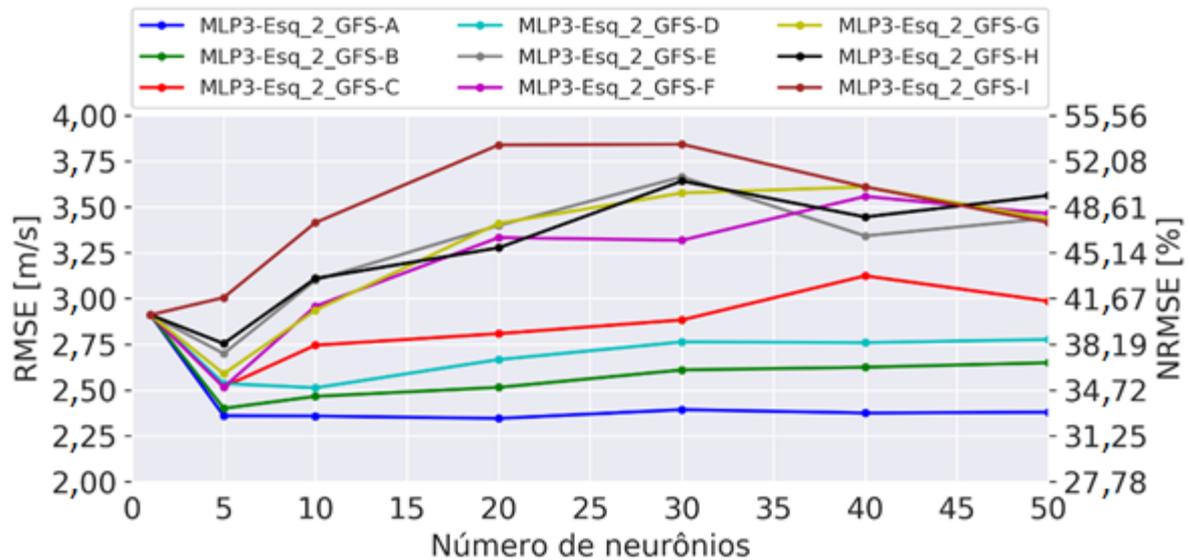
## Parque Eólico Aura Mirim II

Os valores do RMSE médio para o parque eólico Aura Mirim II proveniente provenientes do procedimento de validação cruzada para as redes neurais que prevêem a velocidade do vento pelos esquemas 2, 3 e 4, para os diversos conjuntos de variáveis de entrada e topologias de RNA, encontram-se nas tabelas 22 a 27.

As figuras 40, 41 e 42 representam graficamente os resultados do RMSE médio mostrados na Tabela 23 referentes ao esquema 2 com variáveis de entrada do modelo GFS para o parque MIR-2. Essas figuras servem de exemplo para as demais tabelas que possuem os resultados do RMSE médio do parque MIR-2 desta subseção. Nestes gráficos, percebe-se que há mais *overfitting* quando comparados com os mesmos para o parque Ventos do Sertão. O conjunto de variáveis A é o único que não tem o aumento do RMSE médio com o aumento de neurônios escondidos nas redes com uma, duas e três camadas escondidas.



Figura 42 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq\_2) com os diferentes grupos de variáveis do GFS e redes neurais com três camadas escondidas (MLP3) que prevêem a velocidade do vento na altura do cubo para a torre de referência do parque Aura Mirim II.



Na Tabela 23, nota-se que todos os valores de RMSE médio ficam acima de 2,00 m/s, o que é um erro maior do que o do parque Ventos do Sertão. O menor valor de RMSE médio para o esquema 2, com dados de entrada do GFS e uma camada escondida (MLP1), foi 2,34 m/s, tendo ocorrido para o conjunto A com 40 neurônios escondidos (MLP1-Esq\_2-GFS-A-40neu) e o conjunto C com um neurônio escondido (MLP1-Esq\_2-GFS-C-1neu). Entretanto, o menor desvio padrão para o RMSE médio dos dois conjuntos foi de 0,58 m/s para o MLP1-Esq\_2-GFS-A-40neu. A topologia com duas camadas escondidas (MLP2) apresentou o melhor resultado, com o conjunto de variáveis B e cinco neurônios por camada escondida (MLP2-Esq\_2-GFS-B-5neu), que resultou em um RMSE médio de 2,34 m/s e um desvio padrão de 0,60 m/s. O esquema com o conjunto A e 20 neurônios escondidos por camada (MLP3-Esq\_2-GFS-A-20neu) obteve o melhor RMSE médio, 2,35 m/s, dentre os testes com a topologia de três camadas no esquema dois com variáveis do GFS. Entre as diferentes topologias e conjunto de variáveis do GFS com o esquema 2, o MLP1-Esq\_2-GFS-A-40neu apresentou os menores valores de RMSE médio e desvio padrão do RMSE.

Tabela 23 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêem a velocidade do vento no esquema 2 (Esq\_2) com variáveis do GFS para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [m/s]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-GFS-A	2,36	2,36	2,35	2,35	2,35	2,34	2,34

MLP1-Esq_2-GFS-B	2,36	2,36	2,38	2,39	2,40	2,39	2,39
MLP1-Esq_2-GFS-C	2,34	2,36	2,46	2,51	2,58	2,65	2,68
MLP1-Esq_2-GFS-D	2,37	2,39	2,38	2,41	2,49	2,44	2,42
MLP1-Esq_2-GFS-E	2,41	2,60	2,81	3,43	3,42	3,53	3,66
MLP1-Esq_2-GFS-F	2,88	2,53	2,54	2,68	2,62	2,68	2,69
MLP1-Esq_2-GFS-G	2,88	2,65	2,55	2,69	2,82	2,88	2,95
MLP1-Esq_2-GFS-H	2,86	3,03	3,22	3,38	3,40	3,53	3,63
MLP1-Esq_2-GFS-I	2,43	2,71	3,15	3,23	3,55	3,53	3,91
MLP2-Esq_2-GFS-A	2,91	2,37	2,37	2,35	2,38	2,36	2,38
MLP2-Esq_2-GFS-B	2,91	2,34	2,40	2,45	2,45	2,47	2,52
MLP2-Esq_2-GFS-C	2,91	2,48	2,61	2,78	2,80	2,84	2,88
MLP2-Esq_2-GFS-D	2,91	2,43	2,45	2,58	2,71	2,64	2,75
MLP2-Esq_2-GFS-E	2,91	2,58	2,98	3,49	3,59	3,23	3,40
MLP2-Esq_2-GFS-F	2,91	2,48	2,69	3,09	3,29	3,25	3,21
MLP2-Esq_2-GFS-G	2,91	2,54	3,13	3,13	3,14	3,29	3,34
MLP2-Esq_2-GFS-H	2,91	2,83	3,14	3,45	3,72	3,53	3,66
MLP2-Esq_2-GFS-I	2,91	2,84	3,45	3,46	3,69	3,89	3,65
MLP3-Esq_2-GFS-A	2,91	2,36	2,36	2,35	2,39	2,37	2,38
MLP3-Esq_2-GFS-B	2,91	2,40	2,47	2,51	2,61	2,62	2,65
MLP3-Esq_2-GFS-C	2,91	2,52	2,74	2,81	2,88	3,12	2,99
MLP3-Esq_2-GFS-D	2,91	2,54	2,51	2,67	2,76	2,76	2,78
MLP3-Esq_2-GFS-E	2,91	2,70	3,10	3,40	3,66	3,34	3,44
MLP3-Esq_2-GFS-F	2,91	2,51	2,96	3,33	3,32	3,56	3,46
MLP3-Esq_2-GFS-G	2,91	2,59	2,94	3,41	3,58	3,61	3,44
MLP3-Esq_2-GFS-H	2,91	2,75	3,11	3,28	3,64	3,45	3,56
MLP3-Esq_2-GFS-I	2,91	3,01	3,41	3,84	3,84	3,61	3,41

Os resultados de RMSE médio para o esquema 2 com as variáveis de entrada do GDPS e diferentes topologias de redes neurais são mostrados na Tabela 24. Entre as redes com uma camada escondida, o menor RMSE médio foi 2,27 m/s e ocorreu com o conjunto de variáveis C e um neurônio escondido (MLP1-Esq\_2-GDPS-C-1neu). O menor RMSE médio para a topologia com duas camadas escondidas foi 2,29 m/s e aconteceu com o conjunto A e 10, 40 e 50 neurônios por camada escondida, porém, o MLP2-Esq\_2-GDPS-A-50neu apresentou o menor desvio padrão, que foi de 0,40 m/s. As redes com três camadas escondidas com o conjunto de variáveis A e 5, 20, 40 e 50 neurônios por camada escondida obtiveram o menor valor de RMSE médio para a topologia com três camadas, o qual foi de 2,29 m/s. Entretanto o MLP3-Esq\_2-GDPS-A-50neu apresentou o menor desvio padrão do RMSE médio com 0,40 m/s. Conforme os erros verificados, o melhor representante do esquema 2 com variáveis de entrada do GDPS foi o MLP1-Esq\_2-GDPS-C-1neu.

Tabela 24 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêem a velocidade do vento no esquema 2 (Esq\_2) com variáveis do GDPS para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [m/s]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-GDPS-A	2,28	2,29	2,29	2,30	2,28	2,29	2,29
MLP1-Esq_2-GDPS-B	2,28	2,30	2,32	2,31	2,32	2,30	2,31
MLP1-Esq_2-GDPS-C	2,27	2,31	2,34	2,36	2,45	2,50	2,52
MLP1-Esq_2-GDPS-D	2,29	2,35	2,30	2,29	2,33	2,33	2,33
MLP1-Esq_2-GDPS-E	2,34	2,70	2,83	3,08	3,36	3,43	3,76
MLP1-Esq_2-GDPS-F	2,91	2,53	2,41	2,42	2,49	2,53	2,46
MLP1-Esq_2-GDPS-G	2,96	2,57	2,57	2,58	2,67	2,73	2,73
MLP1-Esq_2-GDPS-H	3,02	2,82	2,96	3,04	3,35	3,52	3,47
MLP1-Esq_2-GDPS-I	2,36	2,64	2,70	2,90	3,07	3,06	3,21
MLP2-Esq_2-GDPS-A	2,91	2,30	2,29	2,31	2,31	2,29	2,29
MLP2-Esq_2-GDPS-B	2,91	2,33	2,35	2,42	2,43	2,49	2,50
MLP2-Esq_2-GDPS-C	2,91	2,35	2,50	2,58	2,68	2,76	2,78
MLP2-Esq_2-GDPS-D	2,91	2,30	2,36	2,43	2,46	2,45	2,45
MLP2-Esq_2-GDPS-E	2,91	2,62	3,06	3,52	3,79	3,96	3,62
MLP2-Esq_2-GDPS-F	2,91	2,43	2,60	2,87	2,92	3,21	3,04
MLP2-Esq_2-GDPS-G	2,91	2,43	2,57	2,77	3,08	3,08	3,33
MLP2-Esq_2-GDPS-H	2,91	2,70	3,04	3,62	3,93	3,59	3,81
MLP2-Esq_2-GDPS-I	2,91	2,57	2,72	3,17	3,41	3,53	3,35
MLP3-Esq_2-GDPS-A	2,91	2,29	2,31	2,29	2,30	2,29	2,29
MLP3-Esq_2-GDPS-B	2,91	2,33	2,38	2,51	2,47	2,50	2,54
MLP3-Esq_2-GDPS-C	2,91	2,33	2,61	2,68	2,84	2,84	2,84
MLP3-Esq_2-GDPS-D	2,91	2,36	2,38	2,57	2,60	2,64	2,69
MLP3-Esq_2-GDPS-E	2,91	2,72	3,76	3,77	3,54	3,53	3,54
MLP3-Esq_2-GDPS-F	2,91	2,45	2,75	3,18	3,38	3,76	3,40
MLP3-Esq_2-GDPS-G	2,91	2,52	2,66	3,16	3,21	3,25	3,24
MLP3-Esq_2-GDPS-H	2,91	2,70	3,17	3,51	3,57	3,49	3,40
MLP3-Esq_2-GDPS-I	2,91	2,57	2,92	3,39	3,47	3,40	3,32

A Tabela 25 apresenta os resultados de RMSE médio obtidos pela validação cruzada das diferentes topologias e conjunto de variáveis do WRF com a grade d01 para o esquema 2 com redes neurais prevendo a velocidade do vento para o parque Aura Mirim II. O conjunto de variáveis A e com 50 neurônios escondidos (MLP1-Esq\_2-WRF-d01-A-50neu) foi a melhor combinação para a topologia com uma camada escondida e os dados de entrada do WRF d01, onde o RMSE médio foi de 2,43 m/s. A topologia com duas camadas escondidas teve seu melhor RMSE médio de 2,45 m/s, o mesmo aconteceu com o conjunto A de variáveis de entrada e 5, 10 e 20 neurônios por camada escondida, entretanto o menor desvio padrão foi de 0,53 m/s para a rede com cinco neurônios. Por isso, o MLP2-Esq\_2-WRF-d01-A-5neu foi considerado

o melhor dentre as redes com duas camadas e os diferentes conjuntos de variáveis do WRF-d01. Dentre os testes com três camadas escondidas, o conjunto de variáveis A com 30 neurônios por camada escondida (MLP3-Esq\_2-WRF-d01-A-30neu) alcançou o menor RMSE médio, 2,44 m/s. O MLP1-Esq\_2-WRF-d01-A-50neu, em virtude de apresentar o menor RMSE médio, foi considerado o representante do esquema 2 que utiliza redes neurais para prever a velocidade do vento e variáveis de entrada do modelo WRF-d01.

Tabela 25 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêem a velocidade do vento no esquema 2 (Esq\_2) com variáveis do WRF-d01 para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [m/s]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-WRF-d01-A	2,46	2,45	2,45	2,46	2,45	2,46	2,43
MLP1-Esq_2-WRF-d01-B	2,47	2,46	2,45	2,46	2,48	2,49	2,49
MLP1-Esq_2-WRF-d01-C	2,44	2,48	2,54	2,54	2,65	2,67	2,81
MLP1-Esq_2-WRF-d01-D	2,48	2,48	2,49	2,54	2,54	2,55	2,56
MLP1-Esq_2-WRF-d01-E	2,53	2,74	2,94	3,31	3,51	3,63	3,82
MLP1-Esq_2-WRF-d01-F	2,88	2,56	2,55	2,69	2,73	2,70	2,78
MLP1-Esq_2-WRF-d01-G	2,88	2,61	2,65	2,76	2,80	2,91	3,00
MLP1-Esq_2-WRF-d01-H	2,83	3,10	3,31	3,49	3,60	3,66	3,55
MLP1-Esq_2-WRF-d01-I	2,49	3,06	3,15	3,34	3,48	3,52	3,65
MLP2-Esq_2-WRF-d01-A	2,91	2,45	2,45	2,45	2,48	2,49	2,46
MLP2-Esq_2-WRF-d01-B	2,91	2,52	2,53	2,56	2,57	2,61	2,61
MLP2-Esq_2-WRF-d01-C	2,91	2,52	2,69	2,85	2,86	2,97	2,92
MLP2-Esq_2-WRF-d01-D	2,91	2,60	2,57	2,76	2,72	2,72	2,76
MLP2-Esq_2-WRF-d01-E	2,91	2,72	3,26	3,84	3,57	3,79	3,75
MLP2-Esq_2-WRF-d01-F	2,91	2,61	2,65	2,89	3,09	3,14	3,27
MLP2-Esq_2-WRF-d01-G	2,91	2,65	2,81	2,99	3,11	3,07	3,33
MLP2-Esq_2-WRF-d01-H	2,91	3,01	3,38	3,51	3,55	3,67	3,56
MLP2-Esq_2-WRF-d01-I	2,91	3,06	3,29	3,43	3,55	3,46	3,45
MLP3-Esq_2-WRF-d01-A	2,91	2,46	2,47	2,50	2,44	2,48	2,47
MLP3-Esq_2-WRF-d01-B	2,91	2,48	2,56	2,59	2,66	2,69	2,73
MLP3-Esq_2-WRF-d01-C	2,91	2,59	2,74	2,94	3,03	3,12	3,11
MLP3-Esq_2-WRF-d01-D	2,91	2,61	2,68	2,72	2,86	2,82	2,82
MLP3-Esq_2-WRF-d01-E	2,91	2,94	3,39	3,65	3,79	3,72	3,47
MLP3-Esq_2-WRF-d01-F	2,91	2,66	2,87	3,16	3,20	3,39	3,40
MLP3-Esq_2-WRF-d01-G	2,91	2,64	2,85	3,11	3,28	3,41	3,32
MLP3-Esq_2-WRF-d01-H	2,91	3,07	3,35	3,44	3,47	3,47	3,35
MLP3-Esq_2-WRF-d01-I	2,91	2,96	3,29	3,35	3,35	3,36	3,14

Na Tabela 26, encontram-se os valores de RMSE médio resultantes da validação cruzada do esquema 2 que utiliza as redes neurais que prevêem a velocidade do vento e conjunto de variáveis de entrada do WRF-d02 para o parque MIR-2. O RMSE médio de 2,45 m/s foi o menor para as redes neurais com uma camada escondida, e o mesmo aconteceu para o conjunto de variáveis A com 50 neurônios escondidos, conjunto B com 5 e 20 neurônios escondidos e conjunto C com um neurônio. Porém, o MLP1-Esq\_2-WRF-d02-C-1neu teve o menor desvio padrão do RMSE médio, com o valor de 0,51 m/s. Para a topologia de duas camadas escondidas, o melhor RMSE médio foi de 2,46 m/s e ocorreu com o conjunto de variáveis A e cinco neurônios escondidos (MLP2-Esq\_2-WRF-d02-A-5neu). O conjunto de variáveis A com 30 neurônios por camada escondida (MLP3-Esq\_2-WRF-d02-A-30neu) obteve o RMSE médio de 2,45 m/s e desvio padrão de 0,53 m/s, o que fez dele o melhor dentre os testes com três camadas escondidas e conjuntos de variáveis do WRF-d02. Por apresentar os menores valores de RMSE médio e desvio padrão do RMSE médio para os testes do esquema 2 que utiliza redes neurais para prever a velocidade do vento e variáveis de entrada do WRF-d02, o MLP1-Esq\_2-WRF-d02-C-1neu foi considerado como seu representante.

Tabela 26 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêem a velocidade do vento no esquema 2 (Esq\_2) com variáveis do WRF-d02 para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [m/s]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-WRF-d02-A	2,48	2,46	2,47	2,48	2,46	2,47	2,45
MLP1-Esq_2-WRF-d02-B	2,47	2,45	2,46	2,45	2,46	2,47	2,47
MLP1-Esq_2-WRF-d02-C	2,45	2,54	2,52	2,53	2,68	2,76	2,74
MLP1-Esq_2-WRF-d02-D	2,48	2,51	2,50	2,55	2,54	2,55	2,57
MLP1-Esq_2-WRF-d02-E	2,54	2,79	2,97	3,33	3,35	3,53	3,56
MLP1-Esq_2-WRF-d02-F	2,87	2,58	2,58	2,62	2,68	2,75	2,75
MLP1-Esq_2-WRF-d02-G	2,87	2,65	2,73	2,88	2,85	2,92	3,00
MLP1-Esq_2-WRF-d02-H	2,80	3,09	3,27	3,39	3,41	3,60	3,55
MLP1-Esq_2-WRF-d02-I	2,55	2,89	3,08	3,23	3,62	3,51	3,66
MLP2-Esq_2-WRF-d02-A	2,91	2,46	2,48	2,47	2,48	2,48	2,48
MLP2-Esq_2-WRF-d02-B	2,91	2,49	2,51	2,55	2,56	2,58	2,58
MLP2-Esq_2-WRF-d02-C	2,91	2,51	2,64	2,80	2,92	2,99	3,00
MLP2-Esq_2-WRF-d02-D	2,91	2,63	2,65	2,70	2,72	2,72	2,72
MLP2-Esq_2-WRF-d02-E	2,91	2,81	3,09	3,71	3,46	3,82	3,60
MLP2-Esq_2-WRF-d02-F	2,91	2,61	2,83	2,92	3,01	3,16	3,17
MLP2-Esq_2-WRF-d02-G	2,91	2,70	2,86	3,07	3,14	3,31	3,33
MLP2-Esq_2-WRF-d02-H	2,91	3,23	3,39	3,50	3,56	3,55	3,42
MLP2-Esq_2-WRF-d02-I	2,91	2,88	3,22	3,45	3,40	3,45	3,38
MLP3-Esq_2-WRF-d02-A	2,91	2,46	2,46	2,48	2,45	2,47	2,48
MLP3-Esq_2-WRF-d02-B	2,91	2,47	2,54	2,58	2,67	2,64	2,65

MLP3-Esq_2-WRF-d02-C	2,91	2,58	2,84	2,89	3,05	3,04	3,05
MLP3-Esq_2-WRF-d02-D	2,91	2,60	2,72	2,74	2,86	2,79	2,82
MLP3-Esq_2-WRF-d02-E	2,91	2,82	3,37	3,52	3,73	3,65	3,64
MLP3-Esq_2-WRF-d02-F	2,91	2,65	2,82	3,17	3,11	3,31	3,35
MLP3-Esq_2-WRF-d02-G	2,91	2,64	2,97	3,26	3,35	3,40	3,48
MLP3-Esq_2-WRF-d02-H	2,91	2,98	3,33	3,59	3,30	3,33	3,37
MLP3-Esq_2-WRF-d02-I	2,91	2,91	3,17	3,18	3,33	3,22	3,08

Os valores de RMSE médio obtidos por meio da validação cruzada das redes neurais que prevêem a velocidade do vento do parque Aura Mirim II para o esquema 3 são apresentados na Tabela 27. O conjunto de variáveis C com um neurônio escondido (MLP1\_Esq\_3-C-1neu) obteve o menor RMSE médio, 2,15 m/s, dentre as redes neurais com uma camada escondida no esquema 3. A topologia de duas camadas escondidas alcançou seu menor RMSE médio, 2,20 m/s, com o conjunto de variáveis A e cinco neurônios por camada escondida (MLP2\_Esq\_3-A-5neu). O menor RMSE médio para as redes neurais com três camadas foi de 2,21 m/s com o conjunto de variáveis A e cinco neurônios por camada escondida (MLP3\_Esq\_3-A-5neu). O representante do esquema 3, com menor RMSE médio, que se utiliza de redes neurais para prever a velocidade do vento do parque MIR-2 é o MLP1\_Esq\_3-C-1neu.

Tabela 27 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêem a velocidade do vento no esquema 3 (Esq\_3) com variáveis do GFS e GDPS para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [m/s]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_3-A	2,18	2,18	2,18	2,20	2,19	2,19	2,18
MLP1-Esq_3-B	2,18	2,22	2,20	2,29	2,37	2,41	2,37
MLP1-Esq_3-C	2,15	2,26	2,32	2,57	2,52	2,61	2,72
MLP1-Esq_3-D	2,18	2,25	2,37	2,50	2,61	2,65	2,73
MLP1-Esq_3-E	2,31	2,61	2,95	3,25	3,28	3,66	3,61
MLP1-Esq_3-F	2,96	2,74	2,53	2,65	2,95	2,99	3,00
MLP1-Esq_3-G	2,93	2,63	2,68	2,81	3,02	3,05	3,13
MLP1-Esq_3-H	2,91	2,99	2,97	3,32	3,51	3,75	3,95
MLP1-Esq_3-I	2,29	2,66	2,88	3,21	3,22	3,41	3,32
MLP2-Esq_3-A	2,91	2,20	2,29	2,30	2,30	2,30	2,34
MLP2-Esq_3-B	2,91	2,28	2,39	2,54	2,67	2,70	2,79
MLP2-Esq_3-C	2,91	2,29	2,47	2,76	2,80	2,99	2,77
MLP2-Esq_3-D	2,91	2,39	2,52	2,92	3,02	3,09	3,23
MLP2-Esq_3-E	2,91	2,58	3,01	3,25	3,45	3,31	3,37
MLP2-Esq_3-F	2,91	2,39	2,73	3,13	3,49	3,53	3,67
MLP2-Esq_3-G	2,91	2,45	2,76	3,27	3,44	3,45	3,52

MLP2-Esq_3-H	2,91	2,66	3,10	3,73	3,78	3,69	3,60
MLP2-Esq_3-I	2,91	2,64	2,86	3,15	3,20	3,22	3,12
MLP3-Esq_3-A	2,91	2,21	2,26	2,34	2,39	2,38	2,45
MLP3-Esq_3-B	2,91	2,23	2,56	2,68	2,80	2,97	2,97
MLP3-Esq_3-C	2,91	2,35	2,62	2,83	2,90	2,94	3,00
MLP3-Esq_3-D	2,91	2,35	2,61	3,09	3,00	3,16	3,05
MLP3-Esq_3-E	2,91	2,73	3,00	3,58	3,27	3,22	3,17
MLP3-Esq_3-F	2,91	2,44	2,84	3,45	3,83	3,38	3,58
MLP3-Esq_3-G	2,91	2,52	2,92	3,32	3,39	3,26	3,13
MLP3-Esq_3-H	2,91	2,77	3,29	3,72	3,70	3,45	3,21
MLP3-Esq_3-I	2,91	2,48	2,95	3,18	3,05	3,09	2,99

A Tabela 28 mostra os resultados de RMSE médio obtidos pela validação cruzada das redes neurais que prevêm a velocidade do vento para o parque Aura Mirim II do esquema 4. A topologia com uma camada escondida teve seu menor RMSE médio, 2,15 m/s, com o conjunto de variáveis C e um neurônio escondido (MLP1-Esq\_4-C-1neu). O menor RMSE médio para as redes neurais com duas camadas escondidas foi de 2,25 m/s e ocorreu com o conjunto de variáveis A e cinco neurônios escondidos por camada escondida (MLP2-Esq\_4-A-5neu). O conjunto A com cinco neurônios por camada escondida (MLP3-Esq\_4-A-5neu) foi o que obteve o menor RMSE médio para os testes do esquema 4 com a topologia de três camadas escondidas. O MLP1-Esq\_4-C-1neu foi considerado o representante do esquema 4 que utiliza redes neurais para prever a velocidade do vento do parque MIR-2.

Tabela 28 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a velocidade do vento no esquema 4 (Esq\_4) com variáveis do GFS, GDPS e WRF-d01 para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [m/s]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_4-A	2,19	2,23	2,25	2,25	2,38	2,34	2,36
MLP1-Esq_4-B	2,16	2,26	2,30	2,37	2,42	2,46	2,49
MLP1-Esq_4-C	2,15	2,32	2,42	2,60	2,61	2,74	2,75
MLP1-Esq_4-D	2,18	2,32	2,61	2,73	2,93	2,98	3,09
MLP1-Esq_4-E	2,34	2,81	3,03	3,33	3,41	3,59	3,65
MLP1-Esq_4-F	3,04	2,64	2,76	3,01	3,12	3,27	3,34
MLP1-Esq_4-G	2,95	2,84	2,81	2,92	3,12	3,09	3,24
MLP1-Esq_4-H	2,78	3,00	3,34	3,24	3,42	3,46	3,48
MLP1-Esq_4-I	2,35	2,70	3,02	3,08	3,21	3,15	3,36
MLP2-Esq_4-A	2,91	2,25	2,33	2,51	2,69	2,62	2,74
MLP2-Esq_4-B	2,91	2,30	2,40	2,59	2,75	2,69	2,73
MLP2-Esq_4-C	2,91	2,37	2,52	2,90	2,88	3,02	2,84
MLP2-Esq_4-D	2,91	2,40	2,66	2,97	3,14	3,24	3,29
MLP2-Esq_4-E	2,91	2,73	3,29	3,46	3,36	3,31	3,27

MLP2-Esq_4-F	2,91	2,46	2,71	3,25	3,44	3,26	3,12
MLP2-Esq_4-G	2,91	2,41	2,77	3,07	3,19	3,13	3,07
MLP2-Esq_4-H	2,91	3,02	3,29	3,41	3,47	3,14	3,05
MLP2-Esq_4-I	2,91	2,75	2,99	3,23	3,20	3,21	3,09
MLP3-Esq_4-A	2,91	2,26	2,41	2,67	2,71	2,66	2,89
MLP3-Esq_4-B	2,91	2,27	2,65	2,92	2,78	2,94	2,81
MLP3-Esq_4-C	2,91	2,34	2,57	2,90	2,93	2,91	2,95
MLP3-Esq_4-D	2,91	2,47	2,83	3,17	3,35	3,09	3,14
MLP3-Esq_4-E	2,91	2,90	3,33	3,25	3,67	3,33	3,06
MLP3-Esq_4-F	2,91	2,47	2,91	3,36	3,24	3,23	2,99
MLP3-Esq_4-G	2,91	2,57	2,89	3,08	3,23	2,94	2,94
MLP3-Esq_4-H	2,91	3,13	3,16	3,43	3,17	3,16	3,12
MLP3-Esq_4-I	2,91	2,73	3,02	3,07	3,08	2,93	2,87

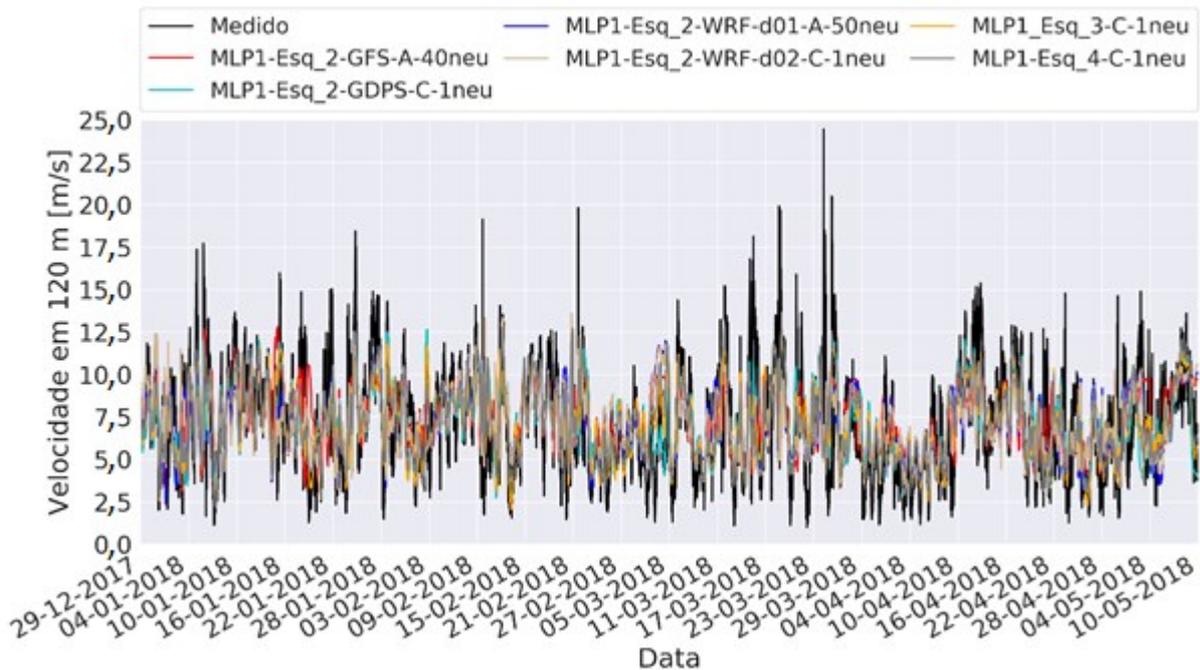
Os melhores resultados para cada um dos esquemas que prevêm a velocidade do vento para o parque Aura Mirim II com redes neurais são apresentados na Tabela 29, onde se pode ver o número de neurônios escondidos, o RMSE médio e o código que indica o número de camadas escondidas, o esquema e o conjunto de variáveis. O RMSE médio de 2,15 m/s foi o mínimo valor encontrado dentre todos os esquemas e ocorreu para o esquema 3 e 4 com o conjunto de variáveis C, uma camada escondida e um neurônio escondido. Estes dois esquemas empregam diferentes modelos de previsão numérica do tempo. O segundo melhor valor de RMSE médio foi de 2,27 m/s e ocorreu com o esquema 2 para o conjunto de variáveis C do GDPS, com uma camada escondida e um neurônio escondido. O pior resultado de RMSE médio foi de 2,45 m/s, tendo ocorrido para o esquema 2 com uma camada escondida, conjunto de variáveis A do WRF-d01 e um neurônio escondido.

Tabela 29 - Melhores topologias das redes neurais que prevêm a velocidade do vento para os esquemas 2, 3 e 4 do parque Aura Mirim II.

<b>Código</b>	<b>Nº de neurônios por camada escondida</b>	<b>RMSE médio [m/s]</b>
MLP1-Esq_2-GFS-A	40	2,34
MLP1-Esq_2-GDPS-C	1	2,27
MLP1-Esq_2-WRF-d01-A	50	2,43
MLP1-Esq_2-WRF-d02-C	1	2,45
MLP1-Esq_3-C	1	2,15
MLP1-Esq_4-C	1	2,15

As séries temporais de velocidade do vento resultantes da junção dos testes da validação cruzada para os melhores representantes de cada esquema que emprega redes neurais para prever a velocidade do vento, indicados na Tabela 29, e a série temporal da velocidade do vento medida em médias de 10 min, na altura de 120,0 m para a torre de referência do parque Aura Mirim II são mostradas na Figura 43. Pode-se observar que os resultados das redes neurais não conseguem acompanhar os picos de velocidade do vento, tal como o que a velocidade chega a 24,5 m/s.

Figura 43 - Série temporal da velocidade do vento em médias de dez minutos medida e da prevista pelas melhores topologias das redes neurais dos esquemas 2, 3 e 4 para o parque Aura Mirim II.



As séries temporais previstas, mostradas na Figura 43, têm suas métricas de performance em relação à série temporal medida do parque Aura Mirim II apresentadas na Tabela 30. Todos os esquemas listados apresentaram RMSE menor que o melhor modelo NWP, que foi o GDPS com 2,52 m/s, valor que pode ser visto na Tabela 11. O RMSE mínimo, dentre os melhores representantes de cada esquema que prevê a velocidade do vento com redes neurais foi de 2,19 m/s e ocorreu com o esquema 3 com uma rede neural de uma camada escondida, um neurônio escondido e conjunto de variáveis C (MLP1\_Esq\_3-C-1neu). Este valor é 13,1 % menor que o melhor RMSE obtido por um modelo NWP. O segundo menor RMSE teve uma diferença de 0,01 m/s em relação ao melhor e foi obtido pelo representante do esquema 4, o

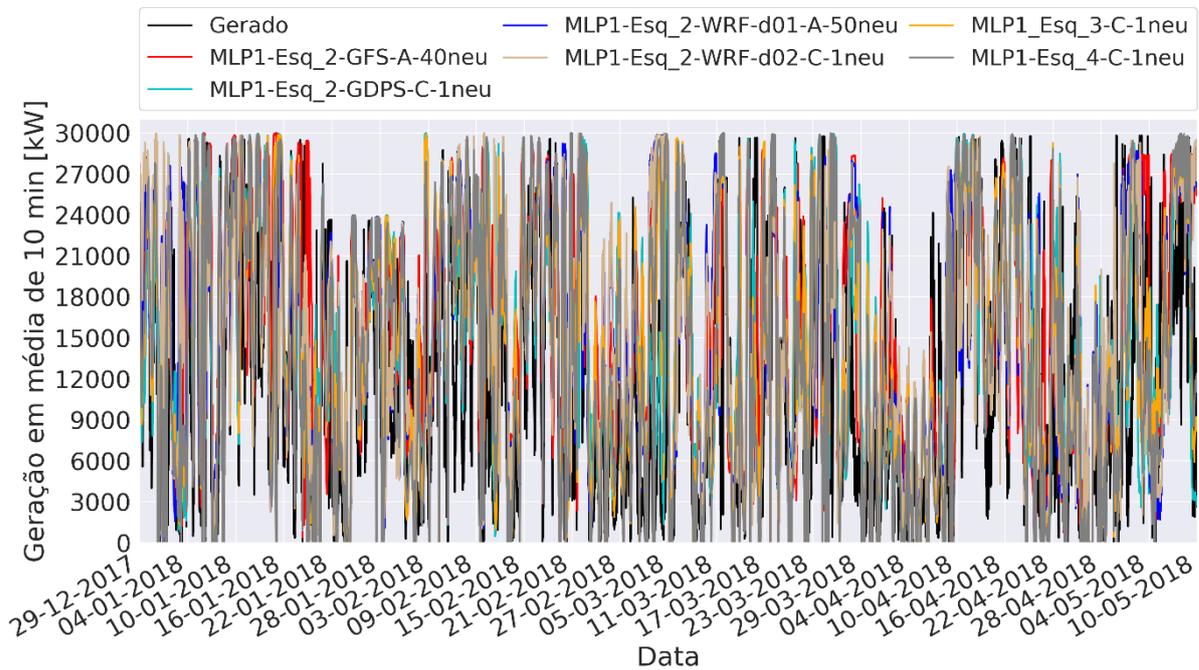
MLP1-Esq\_4-C-1neu, e seu valor foi de 2,20 m/s. O viés de todos os representantes dos esquemas ficaram próximos a zero. O valor do coeficiente de correlação dos representantes dos esquemas 3 e 4 foi de 0,66, que é um valor 6,5 % maior que o melhor valor de  $r$  para um modelo NWP. Todas as representantes dos esquemas para o parque MIR-2 foram redes neurais com uma camada escondida.

Tabela 30 - Métricas de erro para previsão da velocidade pelas redes neurais dos esquemas de previsão com *machine learning* para o parque Aura Mirim II.

<b>Código</b>	<b>RMSE</b> [m/s]	<b>viés</b> [m/s]	<b>NRMSE</b> [%]	<b>NMB</b> [%]	<b>r</b>
MLP1-Esq_2-GFS-A-40neu	2,41	-0,10	33,4	-1,4	0,57
MLP1-Esq_2-GDPS-C-1neu	2,31	0,03	32,1	0,4	0,62
MLP1-Esq_2-WRF-d01-A-50neu	2,49	-0,05	34,6	-0,7	0,54
MLP1-Esq_2-WRF-d02-C-1neu	2,50	-0,05	34,7	-0,7	0,53
MLP1_Esq_3-C-1neu	2,19	0,01	30,5	0,1	0,66
MLP1-Esq_4-C-1neu	2,20	0,03	30,6	0,5	0,66

As séries temporais de geração real do parque Aura Mirim II e obtidas pelo método com redes neurais artificiais que prevêem a velocidade com as melhores topologias e conjuntos de variáveis dos esquemas 2, 3 e 4 são apresentadas na Figura 44.

Figura 44 - Geração real do parque Aura Mirim II e prevista pelo método com redes neurais que prevê a velocidade do vento com a melhor topologia e conjunto de variáveis de cada esquema de previsão.



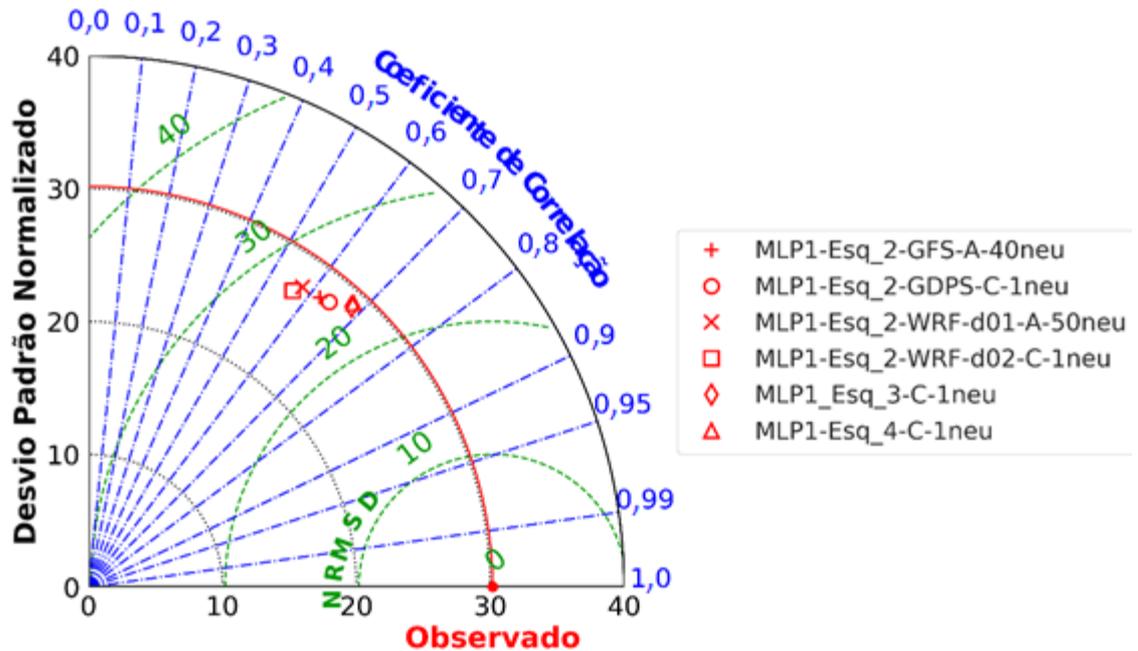
A Tabela 31 apresenta as métricas de erro das previsões de geração do parque Aura Mirim II obtidas pelas melhores topologias e grupos de variáveis dos esquemas que empregaram a velocidade do vento proveniente de redes neurais artificiais. O pior resultado de NRMSE foi de 28,7 % para o esquema 2 com o conjunto de variáveis C do WRF-d02, este também obteve o menor coeficiente de correlação de Pearson,  $r = 0,56$ . O esquema 2, com GDPS, alcançou um resultado de NRMSE 5,6 % melhor em relação ao esquema 2 com o GFS. Os esquemas 3 e 4 que empregam diferentes modelos de previsão numérica do tempo, simultaneamente, com o conjunto de variáveis C, uma camada escondida e um neurônio escondido apresentaram os melhores resultados dentre os demais esquemas, ambos conseguiram um  $r$  de 0,68, que é um valor 21,4 % maior que o obtido pelo esquema 2 com o WRF-d02. O menor NRMSE foi de 25,4 % e ocorreu para o MLP1-Esq\_4-C-1neu, o qual alcançou um NMB de -9,0 %. As melhores topologias e conjunto de variáveis dos esquemas que empregaram o método com redes neurais que prevêem a velocidade do vento subestimaram a geração do parque MIR-2, visto que todos apresentaram valor negativo de NMB. Os esquemas 3 e 4 obtiveram NRMSE iguais a 10,8 % e 11,4 %, respectivamente, menor que o valor obtido pelo esquema 2 com o WRF-d02.

Tabela 31 - Métricas de erro das previsões de geração do parque Aura Mirim II pelas melhores topologias e conjunto de variáveis dos esquemas que empregaram redes neurais na previsão da velocidade do vento.

<b>Código</b>	<b>RMSE [kW]</b>	<b>viés [kW]</b>	<b>NRMSE [%]</b>	<b>NMB [%]</b>	<b>r</b>
MLP1-Esq_2-GFS-A-40neu	8341	-3435	27,8	-11,5	0,62
MLP1-Esq_2-GDPS-C-1neu	7873	-2653	26,2	-8,8	0,64
MLP1-Esq_2-WRF-d01-A-50neu	8590	-3109	28,6	-10,4	0,58
MLP1-Esq_2-WRF-d02-C-1neu	8609	-3037	28,7	-10,1	0,56
MLP1_Esq_3-C-1neu	7684	-2989	25,6	-10,0	0,68
MLP1-Esq_4-C-1neu	7625	-2697	25,4	-9,0	0,68

A representação estatística pelo diagrama de Taylor das melhores topologias e conjunto de variáveis de cada esquema de previsão de geração do parque Aura Mirim II, que se utilizam do método com redes neurais para prever a velocidade do vento, pode ser vista na Figura 45. Os pontos do WRF-d01 e WRF-d02 são os mais distantes do ponto observado, já os pontos mais próximos são os dos esquemas 3 e 4, os quais se sobrepõem. Além de serem os pontos mais próximos ao ponto observado, os esquemas 3 e 4 também são os mais próximos do desvio padrão normalizado dos dados reais, o que indica que acompanham sua variabilidade. Esta sobreposição já era esperada conforme os resultados da Tabela 31. Por apresentar o menor NRMSE e NMB, o MLP1-Esq\_4-C-1neu foi considerado o representante da previsão de geração para o parque Aura Mirim II pelo método com *machine learning* que utiliza redes neurais artificiais para prever a velocidade do vento.

Figura 45 - Representação estatística da previsão de geração pelas melhores topologias e conjunto de variáveis dos esquemas de previsão que utilizam o método com *machine learning* que prevê a velocidade do vento com redes neurais artificiais para o parque Aura Mirim II.



#### 4.3.2 Previsão com redes neurais artificiais do aerogerador equivalente médio

Esta subseção apresenta os resultados de RMSE médio obtidos pela validação cruzada das redes neurais que previram a geração do aerogerador equivalente médio nos esquemas 2, 3 e 4 com diversas topologias de redes e conjunto de variáveis para o parque Ventos do Sertão e Aura Mirim II. As tabelas 31 a 36 mostram os resultados do RMSE médio para o parque SER, já as tabelas 40 a 45 apresentam os resultados para o parque MIR-2. Como já observado, o aumento do número de neurônios pode ocasionar um aumento do RMSE médio, isto ocorre pelo efeito de *overfitting*.

#### Parque Eólico Ventos do Sertão

As figuras 46, 47 e 48 representam graficamente os resultados do RMSE médio resultantes da validação cruzada para o esquema 2 com variáveis de entrada do modelo GFS e diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio do parque Ventos do Sertão. Estes resultados também são apresentados na Tabela 32. Os resultados das outras tabelas, com os demais esquemas de RMSE médio para o parque SER não serão



Figura 47 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq\_2) com os diferentes grupos de variáveis do GFS e redes neurais com duas camadas escondidas (MLP2) que prevêem a geração do aerogerador equivalente médio do parque Ventos do Sertão.

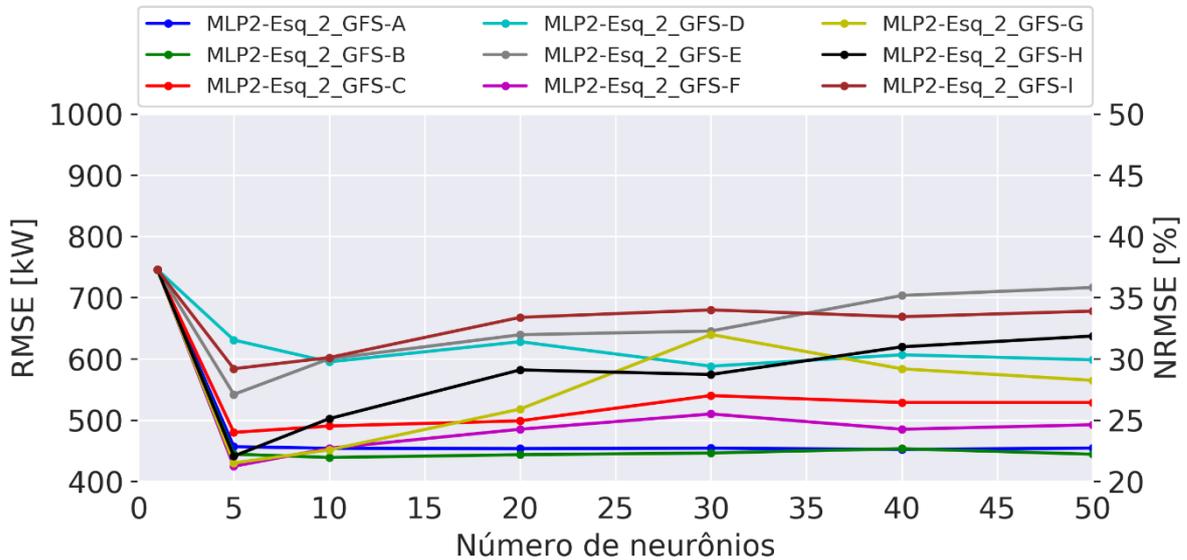
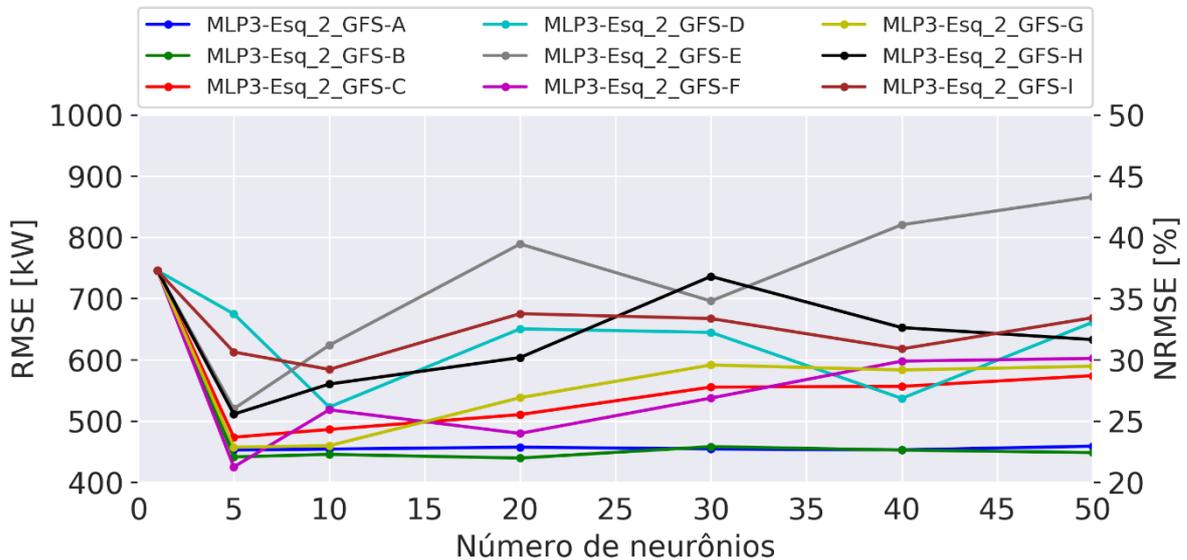


Figura 48 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq\_2) com os diferentes grupos de variáveis do GFS e redes neurais com três camadas escondidas (MLP3) que prevêem a geração do aerogerador equivalente médio do parque Ventos do Sertão.



A Tabela 32 mostra os resultados de RMSE médio da validação cruzada das redes neurais que prevêem a geração do aerogerador equivalente médio do parque Ventos do Sertão para o esquema 2 com conjunto de variáveis do GFS. O conjunto de variáveis F com 30 neurônios escondidos (MLP1-Esq\_2-GFS-F-30neu) foi o que obteve menor RMSE médio dentre as redes com uma camada escondida, valor que foi de 422 kW. O menor RMSE médio para os

testes com redes neurais de duas e três camadas escondidas foi de 425 kW, o que ocorreu também com o conjunto de variáveis F, porém com cinco neurônios por camada escondida. O representante deste esquema foi o MLP1-Esq\_2-GFS-F-30neu, por possuir o menor valor de RMSE médio.

Tabela 32 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 2 (Esq\_2) com variáveis do GFS para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [kW]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-GFS-A	727	673	471	462	461	461	459
MLP1-Esq_2-GFS-B	727	673	460	445	439	439	440
MLP1-Esq_2-GFS-C	727	663	472	471	472	471	467
MLP1-Esq_2-GFS-D	727	524	458	444	444	447	448
MLP1-Esq_2-GFS-E	699	478	453	441	446	441	445
MLP1-Esq_2-GFS-F	727	495	445	427	422	425	426
MLP1-Esq_2-GFS-G	714	471	462	444	439	445	439
MLP1-Esq_2-GFS-H	720	467	458	443	442	444	444
MLP1-Esq_2-GFS-I	582	530	503	484	488	492	495
MLP2-Esq_2-GFS-A	745	457	454	453	454	452	454
MLP2-Esq_2-GFS-B	745	444	439	443	446	453	444
MLP2-Esq_2-GFS-C	745	480	490	499	540	529	529
MLP2-Esq_2-GFS-D	745	631	595	628	588	607	598
MLP2-Esq_2-GFS-E	745	542	600	639	645	703	716
MLP2-Esq_2-GFS-F	745	425	454	485	510	485	492
MLP2-Esq_2-GFS-G	745	430	451	518	640	584	565
MLP2-Esq_2-GFS-H	745	441	502	582	574	620	637
MLP2-Esq_2-GFS-I	745	584	602	668	680	669	678
MLP3-Esq_2-GFS-A	745	453	454	457	454	453	459
MLP3-Esq_2-GFS-B	745	441	445	439	458	452	448
MLP3-Esq_2-GFS-C	745	473	486	510	555	556	574
MLP3-Esq_2-GFS-D	745	675	523	650	645	537	661
MLP3-Esq_2-GFS-E	745	520	624	789	696	820	866
MLP3-Esq_2-GFS-F	745	425	518	480	537	598	602
MLP3-Esq_2-GFS-G	745	457	460	538	591	583	589
MLP3-Esq_2-GFS-H	745	511	560	604	736	652	633
MLP3-Esq_2-GFS-I	745	613	584	675	667	618	669

Os resultados do RMSE médio para o esquema 2, com as variáveis de entrada do GDPS e diferentes topologias de redes neurais, para prever a geração do aerogerador médio do parque SER são apresentados na Tabela 33. O menor RMSE médio, de 479 kW, foi obtido por

uma rede neural com uma camada escondida e ocorreu com o conjunto de variáveis G e 20 neurônios escondidos (MLP1\_Esq\_2-GDPS-G-20neu). A rede neural com duas camadas que obteve o menor valor de RMSE médio, de 459 kW, foi a que aplicou o conjunto de variáveis F e dez neurônios por camada escondida (MLP2\_Esq\_2-GDPS-F-10neu). O conjunto F também foi o que resultou no menor RMSE médio, de 452 kW, dentre os demais para a rede neural com três camadas escondidas, porém com cinco neurônios com camada escondida (MLP3\_Esq\_2-GDPS-F-5neu). A topologia com menor RMSE médio para o esquema 2 e variáveis do GDPS foi a de três camadas escondidas e seu representante foi o MLP3\_Esq\_2-GDPS-F-5neu.

Tabela 33 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 2 (Esq\_2) com variáveis do GDPS para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [kW]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-GDPS-A	727	673	660	542	542	542	540
MLP1-Esq_2-GDPS-B	727	678	663	514	504	502	497
MLP1-Esq_2-GDPS-C	727	679	670	542	549	550	538
MLP1-Esq_2-GDPS-D	727	658	614	591	571	546	552
MLP1-Esq_2-GDPS-E	727	609	524	512	514	527	531
MLP1-Esq_2-GDPS-F	727	674	601	508	489	487	485
MLP1-Esq_2-GDPS-G	727	593	488	479	491	500	501
MLP1-Esq_2-GDPS-H	727	573	508	513	507	517	520
MLP1-Esq_2-GDPS-I	642	522	519	510	535	532	549
MLP2-Esq_2-GDPS-A	745	533	539	541	539	537	536
MLP2-Esq_2-GDPS-B	745	488	489	495	490	495	490
MLP2-Esq_2-GDPS-C	745	528	514	554	576	574	626
MLP2-Esq_2-GDPS-D	745	548	552	998	810	1183	593
MLP2-Esq_2-GDPS-E	745	636	701	695	871	800	891
MLP2-Esq_2-GDPS-F	745	463	459	491	498	488	536
MLP2-Esq_2-GDPS-G	745	460	512	529	545	553	582
MLP2-Esq_2-GDPS-H	745	486	550	610	601	640	661
MLP2-Esq_2-GDPS-I	745	492	582	624	682	647	644
MLP3-Esq_2-GDPS-A	745	539	532	538	541	540	543
MLP3-Esq_2-GDPS-B	745	485	487	495	494	498	509
MLP3-Esq_2-GDPS-C	745	509	537	587	640	621	648
MLP3-Esq_2-GDPS-D	745	567	794	953	951	661	769
MLP3-Esq_2-GDPS-E	745	708	659	831	755	896	953
MLP3-Esq_2-GDPS-F	745	452	469	506	517	551	538
MLP3-Esq_2-GDPS-G	745	459	503	556	564	601	592
MLP3-Esq_2-GDPS-H	745	500	542	643	688	694	613
MLP3-Esq_2-GDPS-I	745	529	552	692	689	668	611

Na Tabela 34, encontram-se os valores de RMSE médio resultantes da validação cruzada das redes neurais que prevêm o aerogerador equivalente médio do parque Ventos do Sertão para o esquema 2 com variáveis de entrada do WRF-d01. O RMSE médio de 440 kW foi o menor valor para as redes neurais com uma camada escondida e deu-se para o conjunto de variáveis F com 30 neurônios escondidos (MLP1-Esq\_2-WRF-d01-F-30neu) e para o conjunto G com 20 neurônios escondidos (MLP1-Esq\_2-WRF-d01-G-20neu), porém o menor desvio padrão do RMSE médio foi de 80 kW e ocorreu com o MLP1-Esq\_2-WRF-d01-F-30neu. O conjunto de variáveis A com 20 neurônios por camada escondida (MLP2-Esq\_2-WRF-d01-A-20neu) foi o que obteve o menor RMSE médio, 452 kW, dentre as redes neurais com duas camadas escondidas. A rede neural com três camadas escondidas, cinco neurônios por camada escondida e conjunto de variáveis A (MLP3-Esq\_2-WRF-d01-A-5neu) obteve o RMSE médio de 452 kW, que foi o menor para a topologia de três camadas escondidas. O MLP1-Esq\_2-WRF-d01-F-30neu possui o menor RMSE médio e desvio padrão, por isto foi considerado o representante do esquema 2 com variáveis do WRF-d01.

Tabela 34 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 2 (Esq\_2) com variáveis do WRF-d01 para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [kW]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-WRF-d01-A	727	673	520	462	458	456	456
MLP1-Esq_2-WRF-d01-B	727	673	472	463	464	463	465
MLP1-Esq_2-WRF-d01-C	727	674	484	487	488	495	499
MLP1-Esq_2-WRF-d01-D	727	560	457	457	462	468	470
MLP1-Esq_2-WRF-d01-E	727	503	457	457	460	450	460
MLP1-Esq_2-WRF-d01-F	727	586	451	441	440	446	444
MLP1-Esq_2-WRF-d01-G	727	536	450	440	448	452	450
MLP1-Esq_2-WRF-d01-H	727	557	499	462	460	473	465
MLP1-Esq_2-WRF-d01-I	727	529	498	488	492	490	512
MLP2-Esq_2-WRF-d01-A	745	455	454	452	455	455	453
MLP2-Esq_2-WRF-d01-B	745	463	470	469	470	469	470
MLP2-Esq_2-WRF-d01-C	745	507	524	542	559	537	575
MLP2-Esq_2-WRF-d01-D	745	847	891	802	916	798	813
MLP2-Esq_2-WRF-d01-E	745	606	704	842	754	786	759
MLP2-Esq_2-WRF-d01-F	745	453	464	467	492	492	493
MLP2-Esq_2-WRF-d01-G	745	457	469	479	509	491	517
MLP2-Esq_2-WRF-d01-H	727	587	515	530	540	526	532
MLP2-Esq_2-WRF-d01-I	745	506	543	624	605	648	582

MLP3-Esq_2-WRF-d01-A	745	452	453	454	456	457	457
MLP3-Esq_2-WRF-d01-B	745	467	464	473	477	476	485
MLP3-Esq_2-WRF-d01-C	745	499	493	548	578	601	594
MLP3-Esq_2-WRF-d01-D	745	713	721	894	806	731	901
MLP3-Esq_2-WRF-d01-E	745	642	948	1011	945	882	669
MLP3-Esq_2-WRF-d01-F	745	459	475	495	510	515	532
MLP3-Esq_2-WRF-d01-G	745	464	460	505	534	540	543
MLP3-Esq_2-WRF-d01-H	727	538	525	527	541	537	554
MLP3-Esq_2-WRF-d01-I	745	514	590	593	600	625	600

Os valores de RMSE médio obtidos da validação cruzada das redes neurais que prevêem a geração do aerogerador equivalente médio com as variáveis de entrada do WRF-d02 para o esquema 2 são mostrados na Tabela 35. A rede neural com uma camada escondida obteve o menor valor de RMSE médio de 442 kW, o qual deu-se para o conjunto de variáveis G com 40 e 50 neurônios escondidos, porém o menor desvio padrão, 88 kW, ocorreu para a rede com 50 neurônios escondidos (MLP1\_Esq\_2-WRF-d02-G-50neu). O conjunto de variáveis F com cinco neurônios por camada escondida (MLP2\_Esq\_2-WRF-d02-F-5neu) foi o que obteve o menor RMSE médio, 454 kW, para as redes neurais com duas camadas escondidas. A topologia com três camadas escondidas teve o menor RMSE médio também com o conjunto de variáveis e cinco neurônios escondidos (MLP3\_Esq\_2-WRF-d02-F-5neu), porém o valor foi de 459 kW. O MLP1\_Esq\_2-WRF-d02-G-50neu foi o que alcançou o menor RMSE médio e desvio padrão para o esquema 2 com variáveis do WRF-d02.

Tabela 35 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêem a geração do aerogerador equivalente médio no esquema 2 (Esq\_2) com variáveis do WRF-d02 para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [kW]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-WRF-d02-A	727	673	524	488	486	485	485
MLP1-Esq_2-WRF-d02-B	727	673	494	485	487	483	483
MLP1-Esq_2-WRF-d02-C	727	676	511	515	515	522	526
MLP1-Esq_2-WRF-d02-D	727	601	474	452	461	457	457
MLP1-Esq_2-WRF-d02-E	727	542	460	445	453	455	453
MLP1-Esq_2-WRF-d02-F	727	591	452	448	450	448	447
MLP1-Esq_2-WRF-d02-G	727	528	449	444	444	442	442
MLP1-Esq_2-WRF-d02-H	727	554	473	458	463	470	467
MLP1-Esq_2-WRF-d02-I	721	518	508	503	488	499	510
MLP2-Esq_2-WRF-d02-A	745	487	483	485	487	484	484
MLP2-Esq_2-WRF-d02-B	745	494	493	496	494	493	494
MLP2-Esq_2-WRF-d02-C	745	528	569	570	585	572	603
MLP2-Esq_2-WRF-d02-D	745	588	594	626	629	543	573
MLP2-Esq_2-WRF-d02-E	745	541	614	578	540	589	557

MLP2-Esq_2-WRF-d02-F	745	454	466	480	485	488	485
MLP2-Esq_2-WRF-d02-G	745	465	478	487	495	502	504
MLP2-Esq_2-WRF-d02-H	727	560	499	518	529	516	512
MLP2-Esq_2-WRF-d02-I	745	513	547	626	614	589	603
MLP3-Esq_2-WRF-d02-A	745	486	483	486	482	479	481
MLP3-Esq_2-WRF-d02-B	745	493	484	496	499	503	500
MLP3-Esq_2-WRF-d02-C	745	527	557	607	581	590	619
MLP3-Esq_2-WRF-d02-D	745	540	514	722	645	631	563
MLP3-Esq_2-WRF-d02-E	745	491	578	533	548	593	598
MLP3-Esq_2-WRF-d02-F	745	459	483	491	511	517	519
MLP3-Esq_2-WRF-d02-G	745	472	491	507	527	538	533
MLP3-Esq_2-WRF-d02-H	727	538	512	522	551	538	528
MLP3-Esq_2-WRF-d02-I	745	541	589	644	624	606	598

A validação cruzada das redes neurais que prevêem a geração do aerogerador equivalente médio do parque SER para o esquema 3, o qual emprega simultaneamente variáveis do GFS e GDPS, resultou em valores de RMSE médio mostrados na Tabela 36. A topologia com uma camada escondida que obteve menor RMSE médio, 440 kW, tinha 50 neurônios escondidos e o conjunto de variáveis B (MLP1-Esq\_3-B-50neu). O conjunto B também foi o que alcançou menor RMSE médio, 441 kW, para as redes neurais com duas camadas escondidas, porém com cinco neurônios por camada escondida (MLP2-Esq\_3-B-5neu). A rede neural com três camadas escondidas que apresentou menor RMSE médio foi a com o conjunto de variáveis B e dez neurônios por camada escondida (MLP3-Esq\_3-B-10neu), sendo o valor de 440 kW. O MLP1-Esq\_3-B-50neu e MLP3-Esq\_3-B-10neu obtiveram o mesmo RMSE médio, que foi o menor dentre todos os demais na Tabela 36. Porém, o MLP1-Esq\_3-B-50neu obteve o menor desvio padrão do RMSE médio, que foi de 78 kW, e por isso foi considerado o representante do esquema três.

Tabela 36 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêem a geração do aerogerador equivalente médio no esquema 3 (Esq\_3) com variáveis do GFS e GDPS para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [kW]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_3-A	727	673	463	452	448	454	452
MLP1-Esq_3-B	727	677	462	456	445	447	440
MLP1-Esq_3-C	727	667	494	463	476	476	484
MLP1-Esq_3-D	717	487	464	451	463	470	461
MLP1-Esq_3-E	621	484	498	476	484	510	487

MLP1-Esq_3-F	721	523	471	468	472	482	473
MLP1-Esq_3-G	651	469	463	454	476	481	482
MLP1-Esq_3-H	700	487	471	481	496	498	516
MLP1-Esq_3-I	580	555	540	522	520	523	536
MLP2-Esq_3-A	745	447	455	460	465	461	483
MLP2-Esq_3-B	745	441	448	455	470	473	472
MLP2-Esq_3-C	745	474	476	487	554	577	571
MLP2-Esq_3-D	745	654	665	996	772	826	865
MLP2-Esq_3-E	745	554	570	746	950	881	866
MLP2-Esq_3-F	745	446	482	509	545	565	565
MLP2-Esq_3-G	745	465	527	531	614	588	621
MLP2-Esq_3-H	745	519	586	634	694	680	647
MLP2-Esq_3-I	745	553	570	601	638	633	627
MLP3-Esq_3-A	745	445	444	461	457	473	468
MLP3-Esq_3-B	745	444	440	488	501	544	535
MLP3-Esq_3-C	745	464	491	530	563	571	563
MLP3-Esq_3-D	745	703	610	727	923	1018	869
MLP3-Esq_3-E	745	607	912	889	904	999	955
MLP3-Esq_3-F	745	448	495	554	580	598	616
MLP3-Esq_3-G	745	500	549	620	620	601	603
MLP3-Esq_3-H	745	498	633	629	646	626	606
MLP3-Esq_3-I	745	579	578	603	598	612	574

A Tabela 37 apresenta os resultados do RMSE médio obtidos pela validação cruzada das redes neurais que prevêm o aerogerador equivalente médio do parque Ventos do Sertão no esquema 4, o qual utiliza simultaneamente variáveis de entrada do GFS, GDPS e WRF-d01. O RMSE médio de 440 kW foi o menor valor alcançado pelas redes neurais com uma camada escondida e ocorreu com o conjunto de variáveis A e 30 neurônios escondidos (MLP1-Esq\_4-A-30neu). A topologia com duas camadas escondidas que apresentou o menor RMSE médio, de 422 kW, foi aquela com cinco neurônios escondidos por camada escondida e conjunto de variáveis A (MLP2-Esq\_4-A-5neu). O conjunto de variáveis B com cinco neurônios por camada escondida foi o que alcançou o menor valor de RMSE médio, 435 kW, para as redes neurais com três camadas escondidas. O menor RMSE médio dentre os testes realizados para o esquema 4 foi de 422 kW e ocorreu para o MLP2-Esq\_4-A-5neu, o que fez deste seu representante.

Tabela 37 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 4 (Esq\_4) com variáveis do GFS, GDPS e WRF-d01 para o parque Ventos do Sertão, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [kW]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_4-A	727	670	450	447	440	453	442

MLP1-Esq_4-B	727	674	454	450	468	460	456
MLP1-Esq_4-C	727	666	472	477	491	506	510
MLP1-Esq_4-D	717	476	458	444	456	468	464
MLP1-Esq_4-E	555	489	485	467	470	465	487
MLP1-Esq_4-F	711	513	476	465	476	468	483
MLP1-Esq_4-G	701	474	467	461	473	470	482
MLP1-Esq_4-H	700	516	514	487	485	490	488
MLP1-Esq_4-I	569	570	537	538	547	534	530
MLP2-Esq_4-A	745	422	440	460	488	506	505
MLP2-Esq_4-B	745	438	471	483	496	512	520
MLP2-Esq_4-C	745	457	498	546	538	549	571
MLP2-Esq_4-D	745	880	1056	1221	1160	1146	1096
MLP2-Esq_4-E	745	648	762	823	897	917	944
MLP2-Esq_4-F	745	439	495	479	562	544	573
MLP2-Esq_4-G	745	476	484	561	575	584	606
MLP2-Esq_4-H	745	490	523	588	617	598	590
MLP2-Esq_4-I	745	530	607	604	622	624	597
MLP3-Esq_4-A	745	446	467	499	499	563	554
MLP3-Esq_4-B	745	435	452	517	555	524	555
MLP3-Esq_4-C	745	461	504	579	601	621	590
MLP3-Esq_4-D	745	871	1001	1049	1143	1062	1230
MLP3-Esq_4-E	745	582	876	965	1014	899	932
MLP3-Esq_4-F	745	471	498	552	577	577	583
MLP3-Esq_4-G	745	475	526	584	611	604	582
MLP3-Esq_4-H	745	518	543	625	603	559	586
MLP3-Esq_4-I	745	582	594	592	592	570	554

Os representantes, melhores topologias e conjunto de variáveis das redes neurais que prevêm a geração do aerogerador equivalente médio do parque Ventos do Sertão para os esquemas 2, 3 e 4 são apresentados na Tabela 38. Observe que o MLP1-Esq\_2-GFS-F e MLP2-Esq\_4-A possuem o menor RMSE médio, de 422 kW. Os resultados de RMSE médio do esquema 2 com o WRF-d01 e o esquema 3 também foram idênticos com o valor de 440 kW. O maior valor de RMSE médio, 452 kW, dentre os esquemas ocorreu com o esquema 2 e GDPS. O esquema 2 com WRF-d02 não obteve um RMSE médio menor que o WRF-d01.

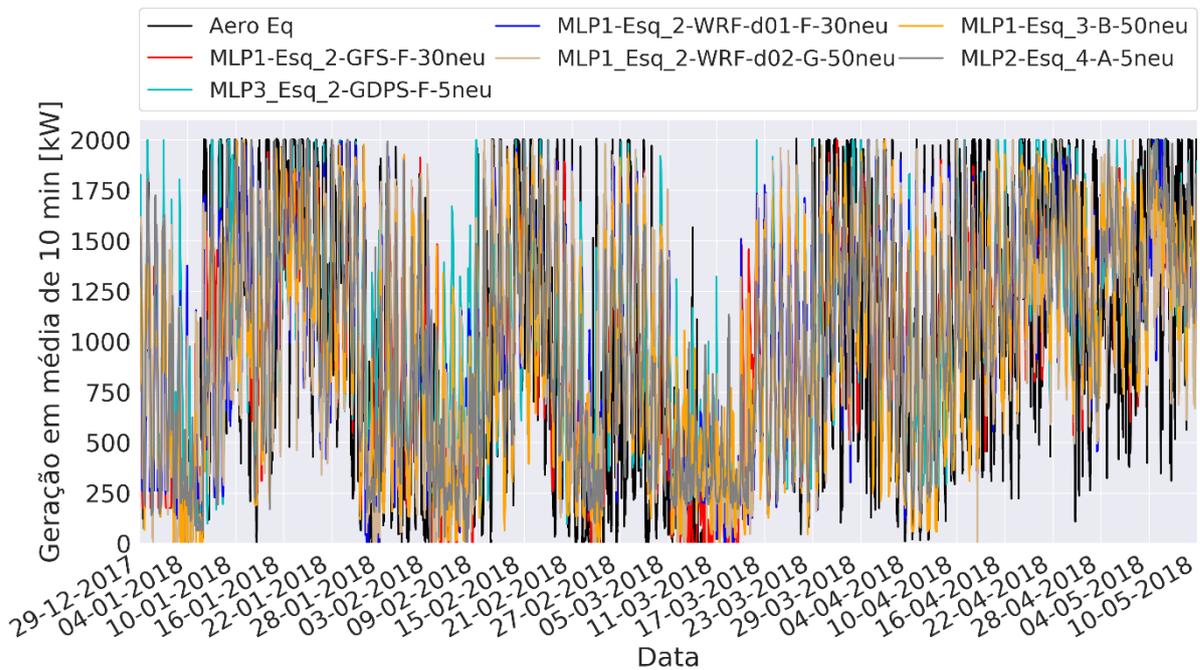
Tabela 38 - Melhores topologias das redes neurais que prevêm a geração do aerogerador equivalente médio para os esquemas 2, 3 e 4 do parque Ventos do Sertão.

<b>Código</b>	<b>Nº de neurônios por camada escondida</b>	<b>RMSE médio [kW]</b>
MLP1-Esq_2-GFS-F	30	422

MLP3_Esq_2-GDPS	5	452
MLP1-Esq_2-WRF-d01-F	30	440
MLP1_Esq_2-WRF-d02-G	50	442
MLP1-Esq_3-B	50	440
MLP2-Esq_4-A	5	422

A geração real do aerogerador equivalente médio do parque Ventos do Sertão e a prevista pelas melhores topologias e conjunto de variáveis dos esquemas 2, 3 e 4 são mostradas na Figura 49.

Figura 49 - Série temporal da geração do aerogerador equivalente médio em médias de dez minutos real (Aero Eq) e previsto pelas melhores topologias das redes neurais dos esquemas 2, 3 e 4 para o parque Ventos do Sertão.



As métricas de erro das séries temporais previstas da geração aerogerador equivalente médio do parque SER pelas melhores topologias e conjunto de variáveis de cada esquema são apresentadas na Tabela 39. Observe que o menor NRMSE foi de 22,3 % para o MLP1-Esq\_2-GFS-F-30neu, porém o MLP2-Esq\_4-A-5neu alcançou um NRMSE próximo com o valor de 22,3 %. A diferença entre o maior e menor valor de NRMSE foi de 1,0 %, o que indica que os modelos tiveram desempenho semelhante. O menor NMB, com o valor de -0,5 %, ocorreu com o MLP1-Esq\_3-B-50neu e o segundo menor, com o valor de -1,1 %, foi obtido pelo MLP1-Esq\_2-GFS-F-30neu. As redes neurais subestimam em parte a potência gerada pelo aerogerador

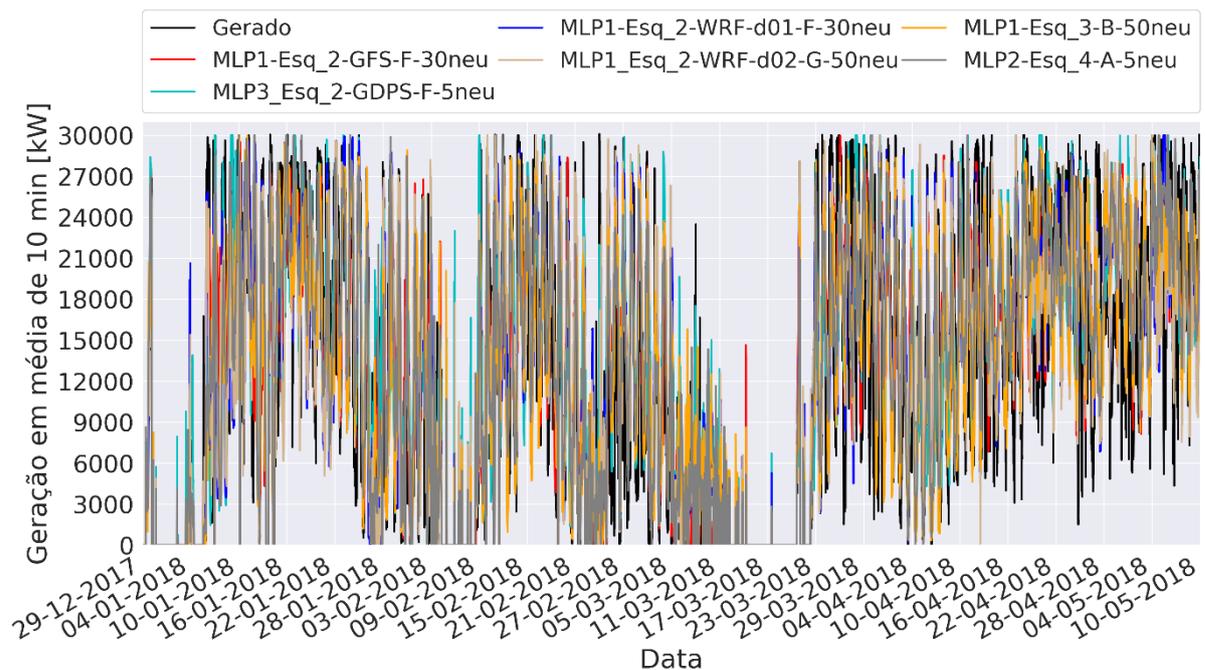
equivalente, visto que os valores de viés são negativos em todas as previsões. O coeficiente de correlação de Pearson em sua maioria ficou acima de 0,70, com o valor máximo de 0,72 para MLP1-Esq\_2-GFS-F-30neu e MLP2-Esq\_4-A-5neu.

Tabela 39 - Métricas de erro para previsão da geração do aerogerador equivalente médio pelas redes neurais dos esquemas de previsão com *machine learning* para o parque Ventos do Sertão.

Código	RMSE [kW]	viés [kW]	NRMSE [%]	NMB [%]	r
MLP1-Esq_2-GFS-F-30neu	446	-22	22,3	-1,1	0,72
MLP3_Esq_2-GDPS-F-5neu	462	-51	23,1	-2,5	0,70
MLP1-Esq_2-WRF-d01-F-30neu	460	-46	23,0	-2,3	0,70
MLP1_Esq_2-WRF-d02-G-50neu	467	-42	23,4	-2,1	0,69
MLP1-Esq_3-B-50neu	459	-10	23,0	-0,5	0,71
MLP2-Esq_4-A-5neu	447	-41	22,3	-2,0	0,72

O gráfico da Figura 50 mostra as séries temporais da geração real do parque Ventos do Sertão e previstas pelos esquemas 2, 3 e 4 com seus melhores representantes.

Figura 50 - Geração real do parque Ventos do Sertão e prevista pelo método com redes neurais que prevêem a geração do aerogerador equivalente médio com a melhor topologia e conjunto de variáveis de cada esquema de previsão.



A Tabela 40 mostra as métricas de performance da previsão da geração do parque Ventos do Sertão pelas melhores topologias e conjunto de variáveis de cada esquema de previsão que emprega redes neurais para prever a geração do aerogerador equivalente médio. O esquema 2 com o conjunto de variáveis F do GFS, uma rede neural com uma camada escondida e 30 neurônios escondidos (MLP1-Esq\_2-GFS-F-30neu) e o esquema 4 com o conjunto de variáveis A, uma rede neural com duas camadas escondidas e cinco neurônios escondidos por camada escondida (MLP2-Esq\_4-A-5neu) obtiveram valores de coeficiente de correlação de Pearson idênticos e valores de NRMSE equivalentes, visto que a diferença foi de 0,02 %. Estes dois esquemas tiveram o menor valor de NRMSE e maior valor de coeficiente de correlação. O pior valor de NRMSE foi de 22,3 % e ocorreu com o MLP1\_Esq\_2-WRF-d02-G-50neu. Os valores negativos de viés mostram que a tendência das previsões é de subestimar a geração real do parque. O MLP1-Esq\_3-B-50neu obteve o NMB de -0,4 % e o MLP1-Esq\_2-GFS-F-30neu de -1,0 %, estes foram os menores valores dentre os demais.

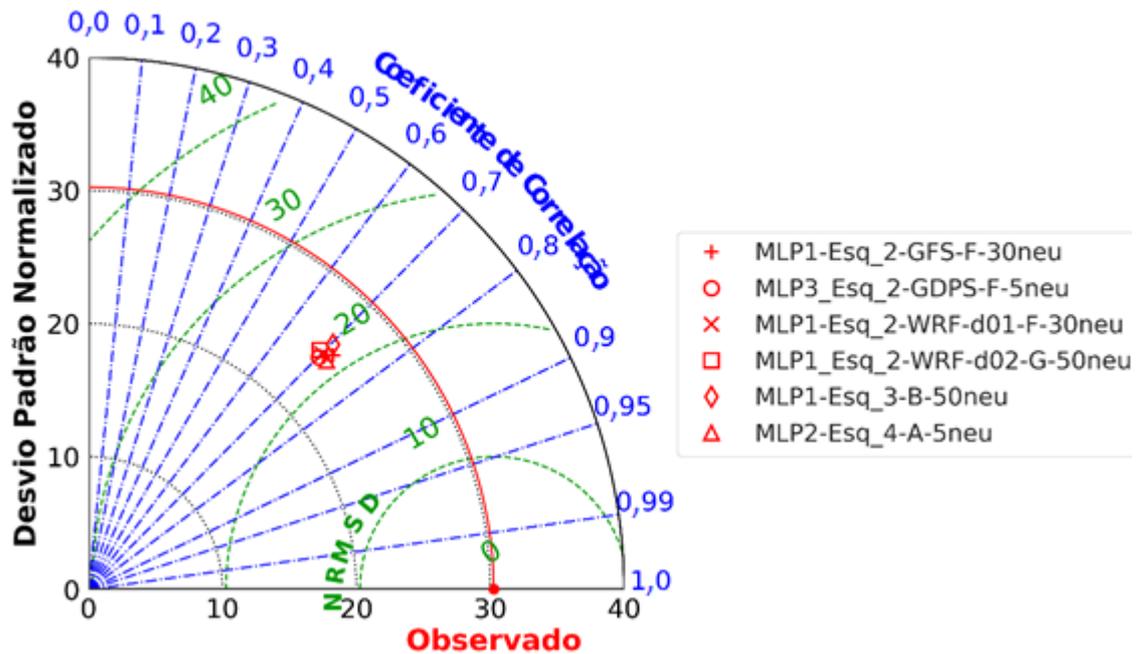
Tabela 40 - Métricas de erro das previsões de geração do parque Ventos do Sertão pelas melhores topologias e conjunto de variáveis dos esquemas que empregaram redes neurais na previsão da geração do aerogerador equivalente médio.

<b>Código</b>	<b>RMSE [kW]</b>	<b>viés [kW]</b>	<b>NRMSE [%]</b>	<b>NMB [%]</b>	<b>r</b>
MLP1-Esq_2-GFS-F-30neu	6404	-303	21,4	-1,0	0,72
MLP3_Esq_2-GDPS-F-5neu	6579	-654	21,9	-2,2	0,70
MLP1-Esq_2-WRF-d01-F-30neu	6582	-633	21,9	-2,1	0,70
MLP1_Esq_2-WRF-d02-G-50neu	6683	-571	22,3	-1,9	0,69
MLP1-Esq_3-B-50neu	6597	-107	22,0	-0,4	0,70
MLP2-Esq_4-A-5neu	6399	-531	21,3	-1,8	0,72

A representação estatística pelo diagrama de Taylor da previsão pelos melhores representantes dos esquemas que utilizam a geração prevista do aerogerador equivalente para obter a geração total do parque é mostrada na Figura 51. Os pontos das previsões quase se superpõem, o que indica o comportamento similar ao representar a realidade. Entretanto o MLP1-Esq\_2-GFS-F-30neu e MLP2-Esq\_4-A-5neu se mostram mais próximos do ponto observado. Porém, o MLP2-Esq\_4-A-5neu é o que tem a menor distância do ponto que representa os dados reais, por este motivo ele foi considerado o que melhor representa o método que emprega redes neurais que prevêm a geração do aerogerador equivalente médio na obtenção da geração total do

parque Ventos do Sertão. O MLP1-Esq\_3-B-50neu é o que possui o desvio padrão mais próximo dos dados reais, visto que possui o menor viés.

Figura 51 - Representação estatística da previsão de geração pelas melhores topologias e conjunto de variáveis dos esquemas de previsão que utilizam o método com *machine learning* que prevê a geração do aerogerador equivalente médio com redes neurais artificiais para o parque Ventos do Sertão.



## Parque Eólico Aura Mirim II

Como informado previamente, as tabelas 40 a 45 apresentam os resultados do RMSE médio obtidos pela validação cruzada das redes neurais que prevêem a geração do aerogerador equivalente médio empregadas nos esquemas 2, 3 e 4 para o parque Aura Mirim II. Os resultados de RMSE médio do esquema 2 com variáveis de entrada do GFS estão presentes na Tabela 41 e são representados graficamente nas figuras 52, 53 e 54, estas servem para exemplificar como seria a representação gráfica das demais tabelas dos outros esquemas. Na Figura 52, nota-se que as topologias com uma camada escondida não apresentam *overfitting* para os diferentes conjuntos de variáveis, já as topologias com duas e três camadas, respectivamente Figura 53 e Figura 54, apresentam *overfitting* para diversos conjuntos. O grupo de variáveis A e B não

sofrem com *overfitting* nas redes com duas e três camadas escondidas do esquema 2 com variáveis de entrada do GFS para o parque MIR-2.

Figura 52 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq\_2) com os diferentes grupos de variáveis do GFS e redes neurais com uma camada escondida (MLP1) que prevêem a geração do aerogerador equivalente médio do parque Aura Mirim II.

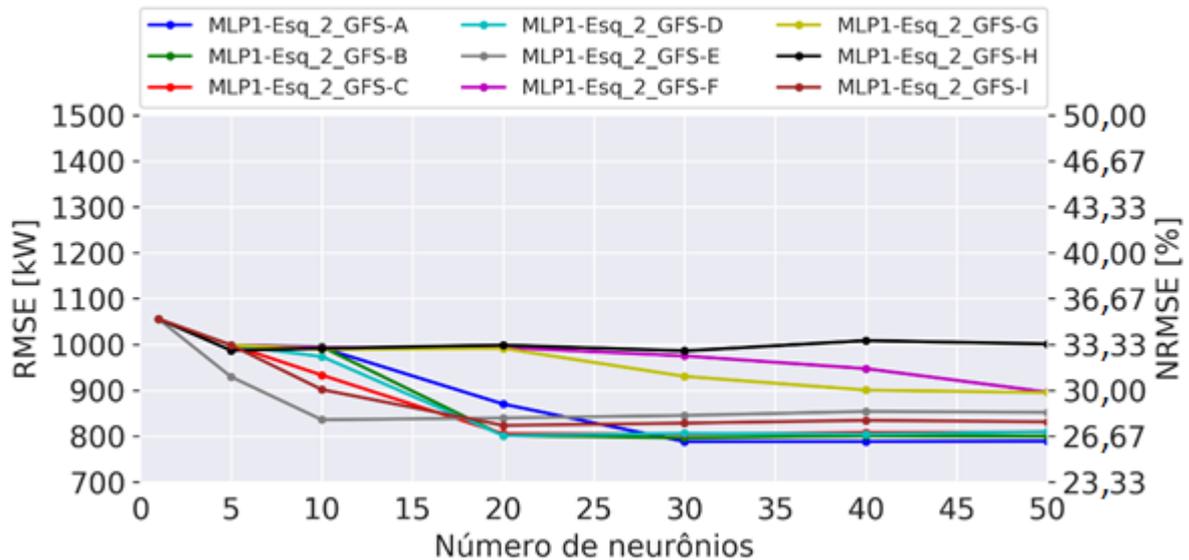


Figura 53 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq\_2) com os diferentes grupos de variáveis do GFS e redes neurais com duas camadas escondidas (MLP2) que prevêem a geração do aerogerador equivalente médio do parque Aura Mirim II.

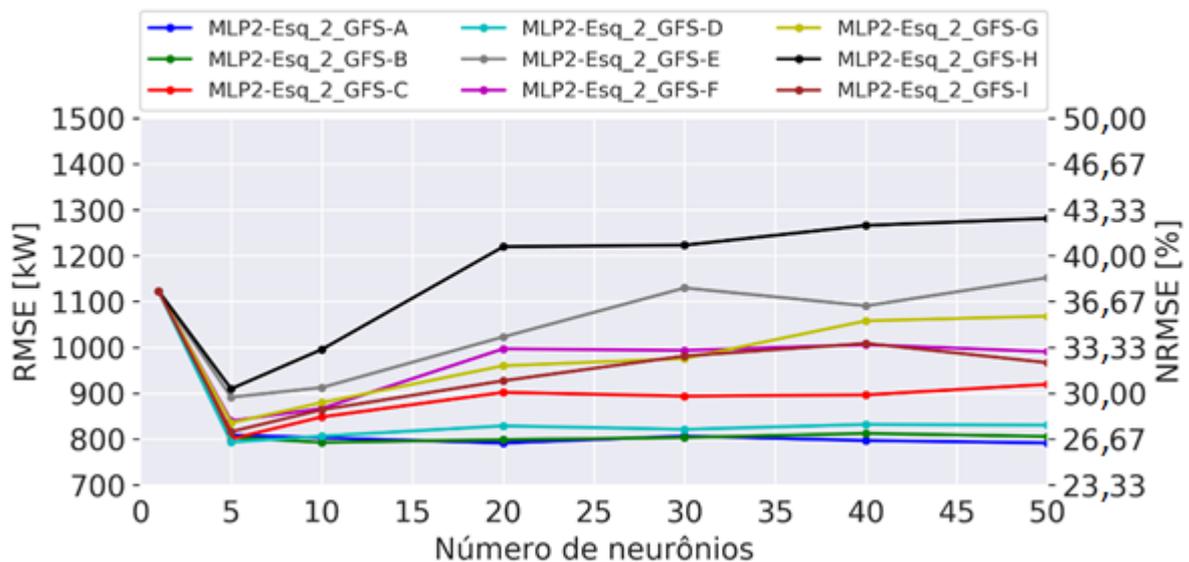
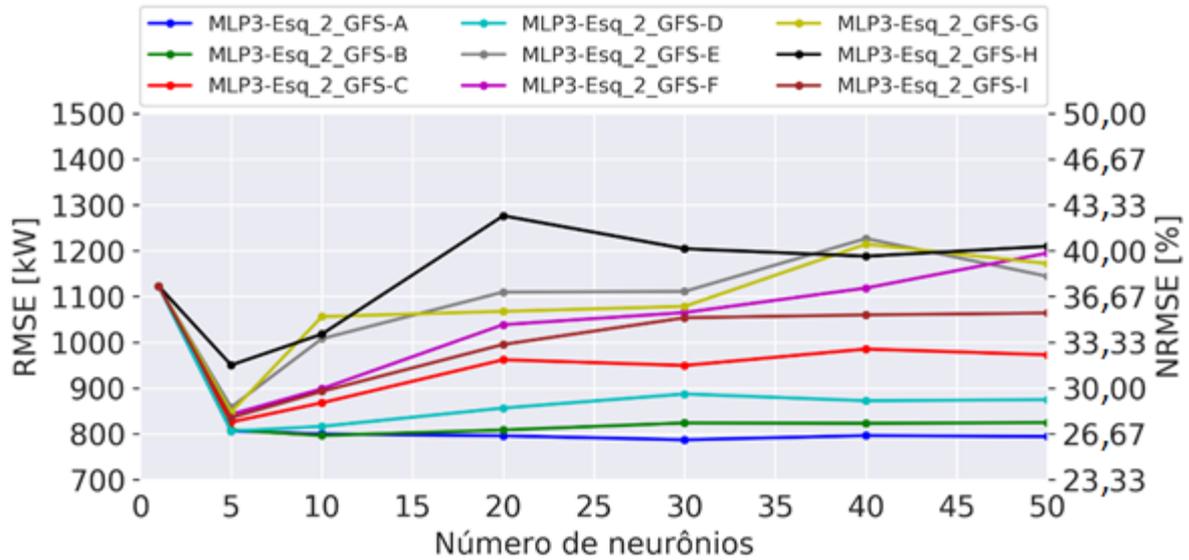


Figura 54 - RMSE e NRMSE médios resultantes dos testes da validação cruzada para o esquema 2 (Esq\_2) com os diferentes grupos de variáveis do GFS e redes neurais com três camadas escondidas (MLP3) que prevêem a geração do aerogerador equivalente médio do parque Aura Mirim II.



A Tabela 41 mostra os resultados de RMSE médio do esquema 2 com os conjuntos de variáveis de entrada do GFS e diferentes topologias de rede neural artificial que prevêem a geração do aerogerador equivalente médio. O RMSE médio de 788 kW foi o menor valor obtido por uma rede neural com uma camada escondida e ocorreu com 30 e 40 neurônios escondidos no conjunto de variáveis A, porém o menor desvio padrão do RMSE médio foi de 184 kW e ocorreu com a rede que possuía 30 neurônios escondidos (MLP1-Esq\_2-GFS-A-30neu). A topologia com duas camadas escondidas que obteve o menor RMSE médio, 791 kW, foi a com 20 neurônios por camada escondida e o conjunto de variáveis A (MLP2-Esq\_2-GFS-A-20neu). O conjunto de variáveis A também foi o que alcançou o menor RMSE médio para a rede neural com três camadas escondidas, porém com 30 neurônios por camada escondida (MLP3-Esq\_2-GFS-A-30neu). O RMSE médio de 787 kW foi o menor valor dentre as topologias e conjuntos de variáveis testados para o esquema 2 com variáveis de entrada do GFS, este valor foi obtido pelo MLP3-Esq\_2-GFS-A-30neu.

Tabela 41 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêem a geração do aerogerador equivalente médio no esquema 2 (Esq\_2) com variáveis do GFS para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [kW]
--------	-----------------

	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-GFS-A	1056	999	993	870	788	788	789
MLP1-Esq_2-GFS-B	1056	999	995	802	796	801	800
MLP1-Esq_2-GFS-C	1056	999	933	805	805	808	809
MLP1-Esq_2-GFS-D	1056	999	973	801	806	805	809
MLP1-Esq_2-GFS-E	1056	929	836	840	845	854	852
MLP1-Esq_2-GFS-F	1056	999	993	993	975	947	896
MLP1-Esq_2-GFS-G	1056	998	989	991	930	900	895
MLP1-Esq_2-GFS-H	1056	987	991	999	986	1008	1001
MLP1-Esq_2-GFS-I	1056	999	902	823	828	834	831
MLP2-Esq_2-GFS-A	1123	809	803	791	806	797	792
MLP2-Esq_2-GFS-B	1123	804	793	799	803	812	806
MLP2-Esq_2-GFS-C	1123	800	848	902	894	896	919
MLP2-Esq_2-GFS-D	1123	793	806	829	821	832	830
MLP2-Esq_2-GFS-E	1123	891	912	1023	1130	1091	1152
MLP2-Esq_2-GFS-F	1123	840	867	997	993	1006	991
MLP2-Esq_2-GFS-G	1123	835	880	960	976	1058	1068
MLP2-Esq_2-GFS-H	1123	910	995	1220	1223	1266	1281
MLP2-Esq_2-GFS-I	1123	816	864	927	981	1009	967
MLP3-Esq_2-GFS-A	1123	806	800	796	787	796	794
MLP3-Esq_2-GFS-B	1123	808	796	808	824	823	825
MLP3-Esq_2-GFS-C	1123	826	868	962	949	985	973
MLP3-Esq_2-GFS-D	1123	806	816	856	887	872	875
MLP3-Esq_2-GFS-E	1123	858	1008	1110	1111	1227	1144
MLP3-Esq_2-GFS-F	1123	843	898	1038	1065	1119	1195
MLP3-Esq_2-GFS-G	1123	848	1056	1068	1079	1214	1172
MLP3-Esq_2-GFS-H	1123	950	1018	1276	1204	1188	1210
MLP3-Esq_2-GFS-I	1123	835	893	995	1054	1060	1064

Os resultados de RMSE médio obtidos da validação cruzada das diferentes topologias de redes neurais e conjunto de variáveis, que prevêm a geração do aerogerador equivalente do parque MIR-2, testadas para o esquema 2 com variáveis de entrada do GDPS são apresentadas na Tabela 42. O conjunto de variáveis A com 30 e 50 neurônios escondidos obtiveram o menor RMSE médio para as redes neurais com uma camada escondida, porém a rede com 50 neurônios (MLP1\_Esq\_2-GDPS-A-50neu) teve o menor desvio padrão do RMSE médio, que foi de 148 kW. A topologia com duas camadas escondidas que alcançou menor RMSE médio, 762 kW, foi a de cinco neurônios por camada escondida com o conjunto de variáveis C (MLP2\_Esq\_2-GDPS-C-5neu). O menor RMSE médio para as redes neurais com três camadas escondidas foi de 766 kW e ocorreu com 30 neurônios por camada escondida e conjunto de variáveis A (MLP3\_Esq\_2-GDPS-A-30neu). MLP2\_Esq\_2-GDPS-C-5neu alcançou o menor RMSE médio dentre as topologias e conjunto de variáveis testadas para o esquema 2 com variáveis de entrada do GDPS.

Tabela 42 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que preveem a geração do aerogerador equivalente médio no esquema 2 (Esq\_2) com variáveis do GDPS para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [kW]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-GDPS-A	1056	991	889	771	770	771	770
MLP1-Esq_2-GDPS-B	1056	992	796	785	785	786	788
MLP1-Esq_2-GDPS-C	1056	987	805	809	801	797	803
MLP1-Esq_2-GDPS-D	1056	993	876	785	788	788	786
MLP1-Esq_2-GDPS-E	1056	982	892	888	903	911	909
MLP1-Esq_2-GDPS-F	1056	999	993	993	941	934	868
MLP1-Esq_2-GDPS-G	1056	999	995	939	884	888	889
MLP1-Esq_2-GDPS-H	1056	994	1012	1047	1026	1015	1019
MLP1-Esq_2-GDPS-I	1123	771	771	771	770	767	771
MLP2-Esq_2-GDPS-A	1123	765	785	795	807	798	809
MLP2-Esq_2-GDPS-B	1123	762	812	829	887	881	883
MLP2-Esq_2-GDPS-C	1123	774	781	790	796	799	795
MLP2-Esq_2-GDPS-D	1123	888	940	1129	1142	1174	1374
MLP2-Esq_2-GDPS-E	1123	806	871	907	959	1070	1025
MLP2-Esq_2-GDPS-F	1123	811	863	900	962	988	980
MLP2-Esq_2-GDPS-G	1123	848	1019	1119	1339	1308	1372
MLP2-Esq_2-GDPS-H	1123	829	994	1057	1120	1230	1190
MLP2-Esq_2-GDPS-I	1123	771	771	771	770	767	771
MLP3-Esq_2-GDPS-A	1123	772	770	768	766	774	773
MLP3-Esq_2-GDPS-B	1123	768	782	784	802	845	834
MLP3-Esq_2-GDPS-C	1123	772	829	886	907	927	914
MLP3-Esq_2-GDPS-D	1123	777	786	802	818	825	826
MLP3-Esq_2-GDPS-E	1123	848	1022	1341	1428	1328	1359
MLP3-Esq_2-GDPS-F	1123	818	873	1023	1093	1061	1124
MLP3-Esq_2-GDPS-G	1123	819	844	966	1053	1041	1124
MLP3-Esq_2-GDPS-H	1123	868	1013	1175	1212	1222	1314
MLP3-Esq_2-GDPS-I	1123	848	1008	1158	1157	1172	1109

Na Tabela 43, encontram-se os resultados de RMSE médio das redes neurais que preveem a geração do aerogerador equivalente médio do parque Aura Mirim II para o esquema 2 com grupos de variáveis de entrada do WRF-d01. O RMSE médio de 837 kW foi o menor valor dentre as redes neurais com uma camada escondida e deu-se para o conjunto de variáveis A com 20 e 30 neurônios escondidos, porém o menor desvio padrão ocorreu com a rede de 20 neurônios escondidos (MLP1-Esq\_2-WRF-d01-A-20neu) e foi de 170 kW. O conjunto de variáveis A com 20 neurônios por camada escondida apresentou o menor RMSE médio para a

topologia com duas e três camadas escondidas, com o valor de, respectivamente, 834 kW e 826 kW. O menor RMSE médio para o esquema 2 com variáveis de entrada do WRF-d01 ocorreu para MLP3-Esq\_2-WRF-d01-A-20neu.

Tabela 43 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 2 (Esq\_2) com variáveis do WRF-d01 para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [kW]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-WRF-d01-A	1056	999	986	837	837	838	838
MLP1-Esq_2-WRF-d01-B	1056	999	961	840	841	842	840
MLP1-Esq_2-WRF-d01-C	1056	999	985	849	853	856	849
MLP1-Esq_2-WRF-d01-D	1056	999	949	848	852	858	858
MLP1-Esq_2-WRF-d01-E	1056	940	911	904	928	902	938
MLP1-Esq_2-WRF-d01-F	1056	999	993	994	969	953	894
MLP1-Esq_2-WRF-d01-G	1056	998	990	944	939	929	921
MLP1-Esq_2-WRF-d01-H	1056	961	985	997	1014	997	1023
MLP1-Esq_2-WRF-d01-I	1056	932	893	890	904	915	918
MLP2-Esq_2-WRF-d01-A	1123	838	838	834	837	839	842
MLP2-Esq_2-WRF-d01-B	1123	844	845	845	860	865	853
MLP2-Esq_2-WRF-d01-C	1123	854	863	942	930	937	958
MLP2-Esq_2-WRF-d01-D	1123	843	853	882	889	900	867
MLP2-Esq_2-WRF-d01-E	1123	889	974	1108	1209	1164	1232
MLP2-Esq_2-WRF-d01-F	1123	864	915	942	996	1005	1004
MLP2-Esq_2-WRF-d01-G	1123	869	923	971	1045	1038	1063
MLP2-Esq_2-WRF-d01-H	1056	1021	1079	1108	1117	1116	1150
MLP2-Esq_2-WRF-d01-I	1123	892	982	1002	1059	1118	1094
MLP3-Esq_2-WRF-d01-A	1123	839	843	826	836	837	838
MLP3-Esq_2-WRF-d01-B	1123	844	840	871	858	866	875
MLP3-Esq_2-WRF-d01-C	1123	840	922	969	978	1003	1011
MLP3-Esq_2-WRF-d01-D	1123	854	873	882	898	916	917
MLP3-Esq_2-WRF-d01-E	1123	934	1003	1205	1225	1258	1211
MLP3-Esq_2-WRF-d01-F	1123	857	927	1065	1067	1165	1125
MLP3-Esq_2-WRF-d01-G	1123	886	967	1024	1110	1109	1113
MLP3-Esq_2-WRF-d01-H	1056	1038	1092	1122	1113	1139	1119
MLP3-Esq_2-WRF-d01-I	1123	917	975	1086	1129	1169	1113

Os valores de RMSE médio obtidos da validação cruzada das redes neurais que prevêm a geração do aerogerador equivalente do parque Aura Mirim II para o esquema 2 com variáveis de entrada do WRF-d02 são apresentados na Tabela 44. A topologia com uma camada escondida apresentou o menor RMSE médio de 838 kW, este deu-se para as redes com 20 e 40 neurônios escondidos com o conjunto de variáveis A, entretanto, a rede com 20 neurônios (MLP1-Esq\_2-WRF-d02-A-20neu) obteve o menor desvio padrão de RMSE médio com 162

kW. O conjunto de variáveis A com dez neurônios por camada escondida foi o que obteve menor RMSE médio (MLP2-Esq\_2-WRF-d02-A-10neu), 834 kW, entre as redes neurais com duas camadas escondidas. O menor RMSE médio para as redes neurais com três camadas escondidas foi de 837 kW e ocorreu para o conjunto A com 10 e 40 neurônios por camada escondida, mas a rede com 40 neurônios (MLP3-Esq\_2-WRF-d02-A-40neu) apresentou menor desvio padrão do RMSE médio, este com o valor de 167 kW. O MLP2-Esq\_2-WRF-d02-A-10neu apresentou o menor RMSE médio para o esquema 2 com variáveis do WRF-d02.

Tabela 44 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêem a geração do aerogerador equivalente médio no esquema 2 (Esq\_2) com variáveis do WRF-d02 para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [kW]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_2-WRF-d02-A	1056	999	993	838	839	838	839
MLP1-Esq_2-WRF-d02-B	1056	999	993	841	841	844	845
MLP1-Esq_2-WRF-d02-C	1056	999	988	853	852	855	856
MLP1-Esq_2-WRF-d02-D	1056	999	993	851	851	856	853
MLP1-Esq_2-WRF-d02-E	1056	953	902	912	918	918	934
MLP1-Esq_2-WRF-d02-F	1056	998	993	993	962	928	899
MLP1-Esq_2-WRF-d02-G	1056	999	989	967	935	937	921
MLP1-Esq_2-WRF-d02-H	1063	996	991	986	1008	1007	1003
MLP1-Esq_2-WRF-d02-I	1055	934	865	884	895	908	929
MLP2-Esq_2-WRF-d02-A	1123	848	834	846	849	846	835
MLP2-Esq_2-WRF-d02-B	1123	850	847	848	856	853	861
MLP2-Esq_2-WRF-d02-C	1123	855	881	910	925	942	956
MLP2-Esq_2-WRF-d02-D	1123	861	854	863	865	871	888
MLP2-Esq_2-WRF-d02-E	1123	896	983	1144	1224	1246	1234
MLP2-Esq_2-WRF-d02-F	1123	860	903	968	967	1029	1014
MLP2-Esq_2-WRF-d02-G	1123	876	922	954	1001	1062	1036
MLP2-Esq_2-WRF-d02-H	1056	1019	1069	1117	1079	1102	1130
MLP2-Esq_2-WRF-d02-I	1123	884	964	1036	1107	1118	1140
MLP3-Esq_2-WRF-d02-A	1123	846	837	840	845	837	843
MLP3-Esq_2-WRF-d02-B	1123	850	857	853	871	868	854
MLP3-Esq_2-WRF-d02-C	1123	854	931	989	1003	989	1029
MLP3-Esq_2-WRF-d02-D	1123	871	856	908	886	895	906
MLP3-Esq_2-WRF-d02-E	1123	896	1062	1207	1211	1201	1179
MLP3-Esq_2-WRF-d02-F	1123	875	917	978	1108	1083	1068
MLP3-Esq_2-WRF-d02-G	1123	877	952	1070	1074	1113	1135
MLP3-Esq_2-WRF-d02-H	1056	1008	1090	1064	1117	1110	1117
MLP3-Esq_2-WRF-d02-I	1123	905	1003	1075	1123	1142	1136

A Tabela 45 apresenta os valores de RMSE médio provenientes da validação cruzada das topologias de redes neurais que prevêm a geração do aerogerador equivalente médio para o esquema 3. Lembrando que o esquema 3 utiliza variáveis de entrada simultaneamente do GFS e GDPS. O RMSE médio de 739 kW foi o menor valor obtido pelas redes neurais de uma camada escondida e ocorreu para o conjunto de variáveis A com 30, 40 e 50 neurônios escondidos, porém o menor desvio padrão, 166 kW, ocorreu com 30 neurônios escondidos (MLP1-Esq\_3-A-30neu). A topologia com duas camadas escondidas que apresentou menor RMSE médio, 735 kW, foi a com cinco neurônios por camada escondida e conjunto de variáveis C (MLP2-Esq\_3-C-5neu). O conjunto de variáveis A com cinco neurônios por camada escondida (MLP3-Esq\_3-A-5neu) foi o que apresentou menor RMSE médio, 740 kW, para a topologia com três camadas escondidas. O menor RMSE médio para as redes neurais que prevêm a geração do aerogerador equivalente médio do esquema 3 ocorreu com o MLP2-Esq\_3-C-5neu.

Tabela 45 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêm a geração do aerogerador equivalente médio no esquema 3 (Esq\_3) com variáveis do GFS e GDPS para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [kW]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_3-A	1056	999	776	743	739	739	739
MLP1-Esq_3-B	1056	999	782	766	760	761	759
MLP1-Esq_3-C	1056	999	776	760	760	760	766
MLP1-Esq_3-D	1056	925	764	783	786	788	772
MLP1-Esq_3-E	1056	853	826	851	849	837	862
MLP1-Esq_3-F	1056	1003	995	1019	1037	990	979
MLP1-Esq_3-G	1056	999	989	1006	963	930	921
MLP1-Esq_3-H	1039	1018	979	1034	1032	1045	1069
MLP1-Esq_3-I	1034	866	851	866	872	864	898
MLP2-Esq_3-A	1123	741	737	745	748	743	742
MLP2-Esq_3-B	1123	739	742	800	836	834	863
MLP2-Esq_3-C	1123	735	800	882	875	942	926
MLP2-Esq_3-D	1123	767	835	816	874	906	890
MLP2-Esq_3-E	1123	850	983	1138	1175	1248	1306
MLP2-Esq_3-F	1123	783	860	950	1138	1203	1172
MLP2-Esq_3-G	1123	810	897	1097	1160	1120	1167
MLP2-Esq_3-H	1123	899	1027	1173	1329	1243	1372
MLP2-Esq_3-I	1123	865	960	1061	1065	1093	1111
MLP3-Esq_3-A	1123	740	743	756	754	763	773
MLP3-Esq_3-B	1123	751	763	863	859	915	913
MLP3-Esq_3-C	1123	754	815	937	980	1007	968
MLP3-Esq_3-D	1123	779	837	937	987	1021	1039
MLP3-Esq_3-E	1123	944	1024	1194	1234	1181	1238
MLP3-Esq_3-F	1123	806	927	1143	1175	1234	1218

MLP3-Esq_3-G	1123	821	956	1170	1233	1145	1184
MLP3-Esq_3-H	1123	895	1102	1283	1256	1222	1263
MLP3-Esq_3-I	1123	866	1012	1078	1129	1111	1139

A validação cruzada das redes neurais que prevêem a geração do aerogerador equivalente médio para o parque MIR-2 do esquema 4 resultou em valores de RMSE médio que são mostrados na Tabela 46. O conjunto de variáveis C com 40 neurônios escondidos (MLP1-Esq\_4-C-40neu) foi o que obteve menor RMSE médio, 758 kW, para as redes neurais com uma camada escondida. O RMSE médio de 748 kW foi o menor valor para as redes com duas camadas escondidas, o qual ocorreu com cinco neurônios por camada escondida e o conjunto de variáveis A (MLP2-Esq\_4-A-5neu). A topologia com três camadas escondidas que obteve o menor RMSE médio, 745 kW, foi a com cinco neurônios por camada escondida e conjunto de variáveis A (MLP3-Esq\_4-A-5neu). O melhor resultado da validação cruzada das redes neurais do esquema 4 ocorreu para o MLP3-Esq\_4-A-5neu.

Tabela 46 - RMSE médio resultante do procedimento de validação cruzada para as diferentes topologias de redes neurais que prevêem a geração do aerogerador equivalente médio no esquema 4 (Esq\_4) com variáveis do GFS, GDPS e WRF-d01 para o parque Aura Mirim II, onde n. indica o número de neurônios por camada escondida.

Código	RMSE médio [kW]						
	1 n.	5 n.	10 n.	20 n.	30 n.	40 n.	50 n.
MLP1-Esq_4-A	1056	999	777	759	768	776	770
MLP1-Esq_4-B	1056	999	785	774	773	774	776
MLP1-Esq_4-C	1056	999	778	775	765	758	766
MLP1-Esq_4-D	1056	937	809	802	794	796	817
MLP1-Esq_4-E	1057	864	845	871	859	867	900
MLP1-Esq_4-F	1056	991	997	1029	993	981	974
MLP1-Esq_4-G	1056	991	980	971	929	926	938
MLP1-Esq_4-H	1055	968	961	959	954	948	941
MLP1-Esq_4-I	1056	908	885	903	874	873	885
MLP2-Esq_4-A	1123	748	771	806	803	781	810
MLP2-Esq_4-B	1123	751	792	825	892	923	912
MLP2-Esq_4-C	1123	753	851	946	1004	1009	934
MLP2-Esq_4-D	1123	794	856	927	999	1045	1088
MLP2-Esq_4-E	1123	886	1061	1125	1329	1296	1269
MLP2-Esq_4-F	1123	813	895	1016	1127	1159	1214
MLP2-Esq_4-G	1123	814	910	1075	1116	1103	1133
MLP2-Esq_4-H	1123	984	1052	1150	1196	1175	1208
MLP2-Esq_4-I	1123	917	990	1040	1069	1122	1070
MLP3-Esq_4-A	1123	745	799	804	855	857	895
MLP3-Esq_4-B	1123	761	821	924	955	946	945

MLP3-Esq_4-C	1123	770	854	987	984	996	1048
MLP3-Esq_4-D	1123	804	900	1047	1134	1048	1128
MLP3-Esq_4-E	1123	972	1049	1206	1330	1264	1221
MLP3-Esq_4-F	1123	845	940	1148	1142	1202	1224
MLP3-Esq_4-G	1123	853	959	1062	1125	1100	1064
MLP3-Esq_4-H	1123	1031	1117	1158	1143	1153	1117
MLP3-Esq_4-I	1123	906	1071	1176	1106	1145	1035

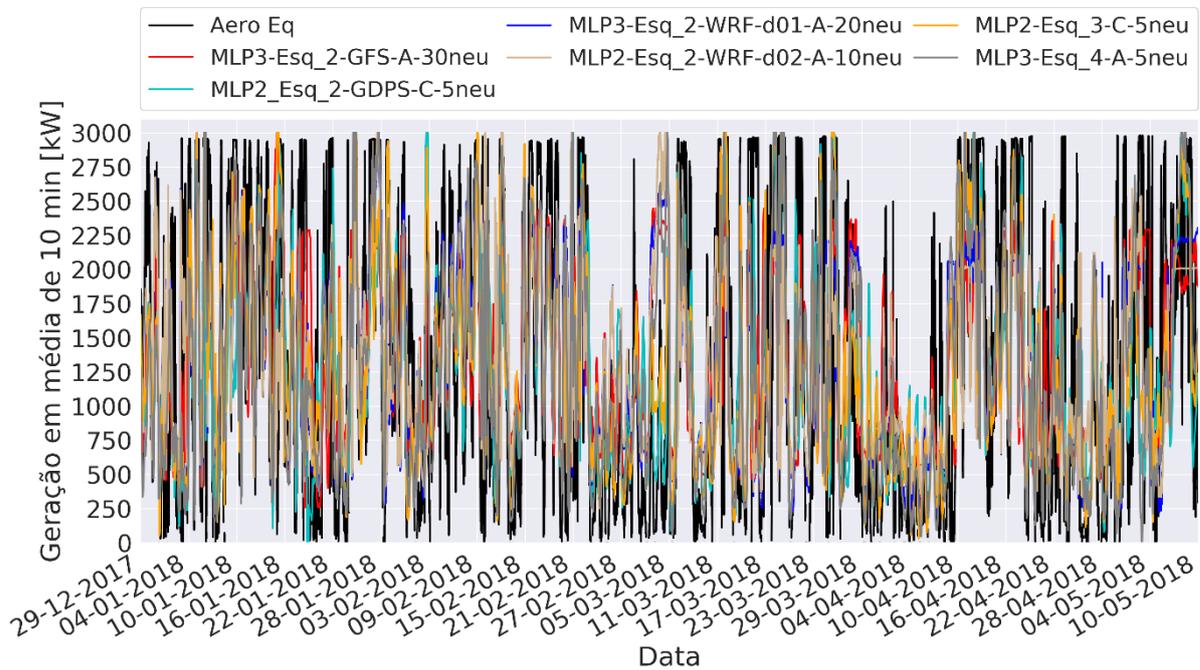
A Tabela 47 apresenta as melhores topologias de redes neurais que prevêm a geração do aerogerador equivalente médio do parque Aura Mirim II para os esquemas 2, 3 e 4. Os maiores valores de RMSE médio ocorreram para o esquema 2 com o WRF nas duas grades, o que indica que a utilização do modelo de mesoescala não é efetiva para o parque MIR-2. O esquema 3 apresentou o menor RMSE médio, isto mostra que os modelos globais em conjunto geram um melhor resultado, visto que o esquema 3 emprega simultaneamente variáveis de entrada do GFS e GDPS. Percebe-se que todas as melhores topologias possuíam duas ou três camadas escondidas para as redes neurais que prevêm a geração do aerogerador equivalente do parque MIR-2. Com 745 kW de RMSE médio, o esquema 4 foi o segundo melhor, o que fortalece a importância do uso de diferentes modelos de previsão numérica do tempo de forma simultânea para MIR-2.

Tabela 47 - Melhores topologias das redes neurais que prevêm a geração do aerogerador equivalente médio para os esquemas 2, 3 e 4 do parque Aura Mirim II.

<b>Código</b>	<b>Nº de neurônios por camada escondida</b>	<b>RMSE médio [kW]</b>
MLP3-Esq_2-GFS-A	30	787
MLP2_Esq_2-GDPS-C	5	762
MLP3-Esq_2-WRF-d01-A	20	826
MLP2-Esq_2-WRF-d02-A	10	834
MLP2-Esq_3-C	5	735
MLP3-Esq_4-A	5	745

As séries temporais previstas do aerogerador equivalente médio pelas melhores topologias de redes neurais e melhores conjunto de variáveis dos esquemas 2, 3 e 4 são mostradas na Figura 55 em conjunto com os dados medidos.

Figura 55 - Série temporal da geração do aerogerador equivalente médio em médias de 10 min real (Aero Eq) e prevista pelas melhores topologias das redes neurais dos esquemas 2, 3 e 4 para o parque Aura Mirim II.



Os erros calculados para as séries previstas do aerogerador equivalente médio, mostradas na Figura 55, são apresentados na Tabela 48. O menor NRMSE e coeficiente de correlação de Pearson ocorreram com o representante do esquema 3, MLP3-Esq\_2-WRF-d01-A-20neu, e foram respectivamente de 24,8 % e 0,66. Os piores desempenhos ocorreram com o esquema 2 utilizando variáveis de entrada do WRF com as d01 e d02. O esquema 4 desempenhou bem, seguido pelo esquema 2 com GDPS e GFS. O menor NMB foi de 0,6 % e deu-se com o esquema 2 com variáveis do GFS.

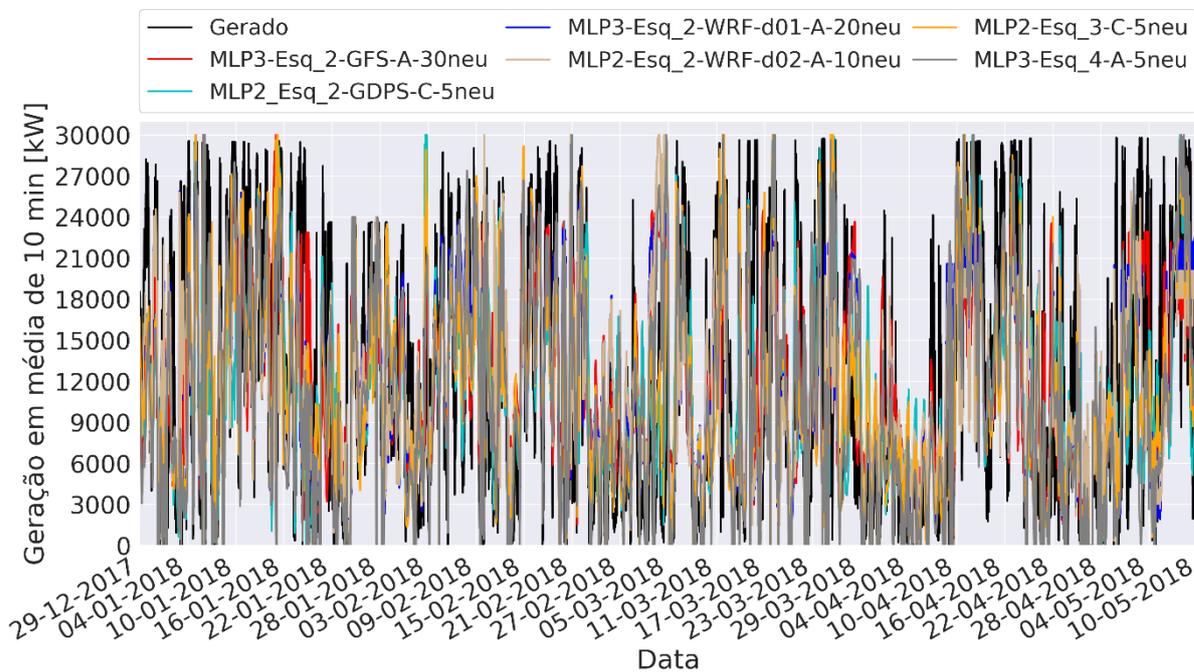
Tabela 48 - Métricas de erro para previsão da geração do aerogerador equivalente médio pelas redes neurais dos esquemas de previsão com *machine learning* para o parque Aura Mirim II.

Código	RMSE [kW]	viés [kW]	NRMSE [%]	NMB [%]	r
MLP3-Esq_2-GFS-A-30neu	806	17	26,9	0,6	0,58
MLP2_Esq_2-GDPS-C-5neu	772	68	25,8	2,3	0,63
MLP3-Esq_2-WRF-d01-A-20neu	843	33	28,1	1,1	0,53
MLP2-Esq_2-WRF-d02-A-10neu	850	36	28,3	1,2	0,52
MLP2-Esq_3-C-5neu	744	54	24,8	1,8	0,66

MLP3-Esq_4-A-5neu	767	50	25,6	1,7	0,64
-------------------	-----	----	------	-----	------

Com o resultado das séries temporais do aerogerador equivalente proveniente das redes neurais foi possível calcular a geração total prevista pelas melhores topologias e conjunto de variáveis dos esquemas 2, 3 e 4 para o parque Aura Mirim II, tais séries temporais são mostradas na Figura 56.

Figura 56 - Geração real do parque Aura Mirim II e prevista pelo método com redes neurais que prevêem a geração do aerogerador equivalente médio com a melhor topologia e conjunto de variáveis de cada esquema de previsão.



A Tabela 49 apresenta as métricas de erro das previsões da geração total do parque Aura Mirim II pelos melhores representantes do esquema 2, 3 e 4 que se utilizam de redes neurais para prever a geração do aerogerador equivalente médio. O menor NRMSE foi de 22,4 % e o maior coeficiente de correlação foi 0,68 - valores obtidos pelo esquema 3, o qual emprega variáveis do GFS e GDPS simultaneamente. O esquema 4 foi o segundo melhor no NRMSE, porém com valor muito próximo ao esquema 2 com o GDPS. O menor NMB foi de 0,6 % e ocorreu com o esquema 2 com variáveis de entrada do GFS.

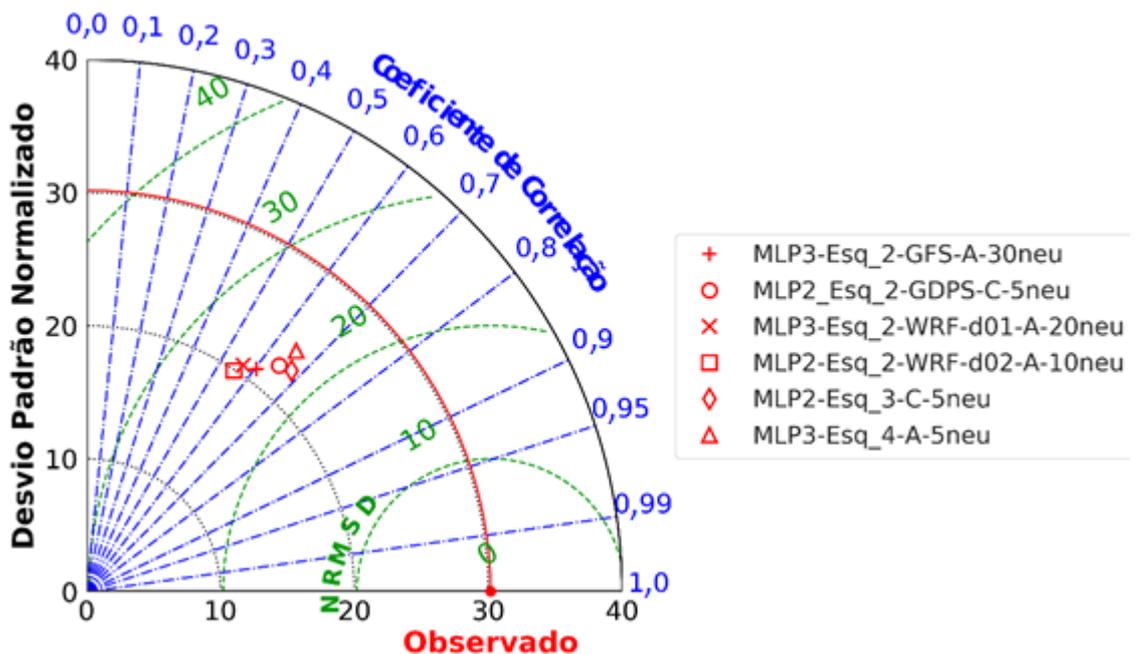
Tabela 49 - Métricas de erro das previsões de geração do parque Aura Mirim II pelas melhores topologias e conjunto de variáveis dos esquemas que empregaram redes neurais na previsão da geração do aerogerador equivalente médio.

Código	RMSE	viés	NRMSE	NMB	r
--------	------	------	-------	-----	---

	[kW]	[kW]	[%]	[%]	
MLP3-Esq_2-GFS-A-30neu	7267	164	24,2	0,6	0,60
MLP2_Esq_2-GDPS-C-5neu	6998	669	23,3	2,2	0,65
MLP3-Esq_2-WRF-d01-A-20neu	7549	319	25,2	1,1	0,57
MLP2-Esq_2-WRF-d02-A-10neu	7621	354	25,4	1,2	0,55
MLP2-Esq_3-C-5neu	6708	518	22,4	1,7	0,68
MLP3-Esq_4-A-5neu	6982	474	23,3	1,6	0,65

O diagrama de Taylor, na Figura 57, representa estatisticamente as melhores topologias e conjunto de variáveis de cada esquema. Nota-se que o esquema 2 com WRF-d01 e WRF-d02 são os pontos mais distantes do observado, isto indica que eles são os piores dentre os demais. O esquema 4 apresenta desvio padrão normalizado mais similar aos dados reais, entretanto o esquema 3 é o mais próximo ao ponto observado, por isto o MLP2-Esq\_3-C-5neu é considerado o representante do método com *machine learning* que utiliza redes neurais para prever a geração do aerogerador equivalente médio para o parque de Aura Mirim II.

Figura 57 - Representação estatística da previsão de geração pelas melhores topologias e conjunto de variáveis dos esquemas de previsão que utilizam o método com *machine learning* que prevê a geração do aerogerador equivalente médio com redes neurais artificiais para o parque Aura Mirim II.



#### 4.4 COMPARAÇÃO ENTRE OS MÉTODOS

Os melhores representantes do método físico, método de previsão de geração com a velocidade do vento obtida por redes neurais artificiais (Método RNA – Vel. do Vento) e método de previsão de geração com o aerogerador equivalente médio obtido por redes neurais artificiais (Método RNA – Aero. Eq.) foram estabelecidos para o parque de Ventos do Sertão e Aura Mirim II nas seções 4.2 e 4.3. A presente seção tem por objetivo comparar o desempenho dos representantes de cada método entre si. O método físico é considerado o método base para se avaliar os ganhos dos demais.

##### Parque Eólico Ventos do Sertão

A Tabela 50 mostra o código do melhor representante de cada método de previsão de geração total do parque acompanhado das métricas de erro obtidas para Ventos do Sertão. O representante do método físico é o resultado do esquema 1 com a velocidade do modelo de mesoescala WRF na grade d01, com 12 km de resolução espacial. A rede neural com uma camada escondida, um neurônio escondido, com o conjunto de variáveis de entrada H do GFS no esquema 2 (MLP1-Esq\_2-GFS-H-1neu) foi escolhida como representante do método de previsão de geração com a velocidade obtida por redes neurais artificiais (Método RNA – Vel. do Vento). O conjunto de variáveis com A no esquema 4 com uma rede neural de duas camadas escondidas e cinco neurônios por camada escondida (MLP2-Esq\_4-A-5neu) representa o método de previsão de geração com o aerogerador equivalente médio obtido por redes neurais artificiais (Método RNA – Aero. Eq.). Observa-se que para o método que prevê a velocidade do vento por redes neurais o modelo global GFS foi o que se destacou, já para o método que prevê o aerogerador equivalente por redes neurais teve como selecionado o esquema 4, o qual emprega simultaneamente as variáveis do GFS, GDPS e WRF-d01.

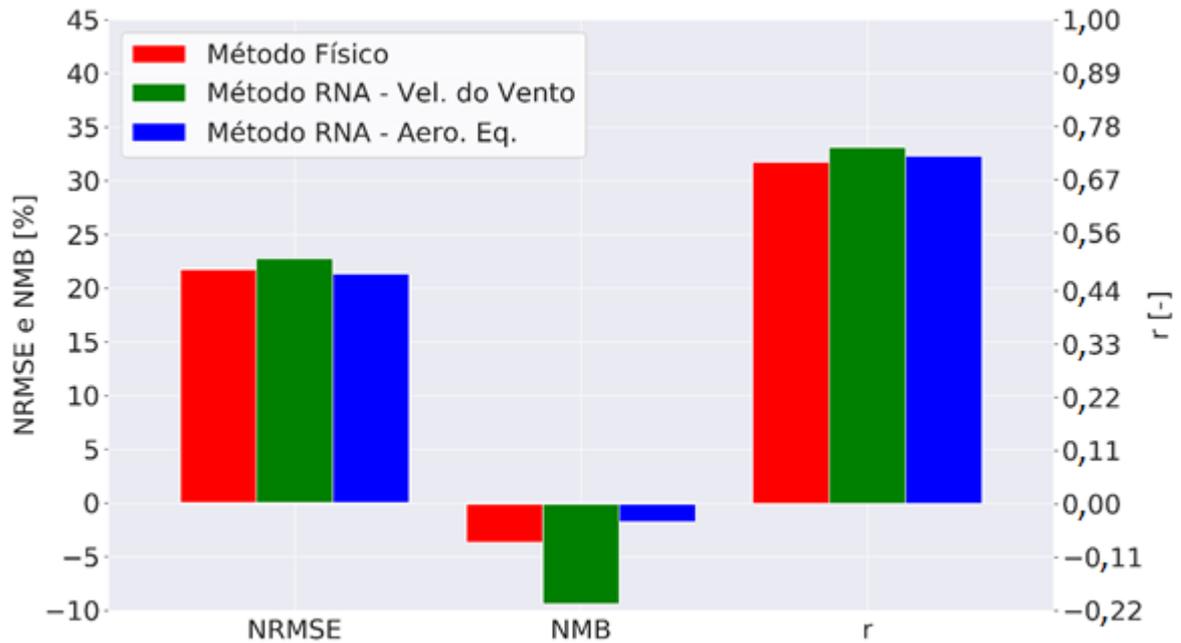
Tabela 50 - Representantes de cada método para o parque Ventos do Sertão.

Método	Código	NRMSE [%]	NMB [%]	r
Método Físico	WRF-d01	21,8	-3,7	0,71
Método de previsão de geração com a velocidade obtida	MLP1-Esq_2-GFS-H-1neu	22,8	-9,4	0,74

por redes neurais artificiais (Método RNA – Vel. do Vento)				
Método de previsão de geração com o aerogerador equivalente médio obtido por redes neurais artificiais (Método RNA – Aero. Eq.)	MLP2-Esq_4-A-5neu	21,3	-1,8	0,72

As métricas dos erros dos representantes de cada método, presente na Tabela 50, são mostradas graficamente na Figura 58. Os valores de NRMSE e do coeficiente de correlação de Pearson ( $r$ ) foram próximos uns dos outros, porém a diferença no erro médio normalizado (NMB) foi maior. A geração do parque é subestimada pelos métodos de previsão, visto que todos apresentam valores negativos de NMB. O método que emprega o aerogerador equivalente médio obteve o menor valor de NRMSE com 21,3 % e menor valor de NMB com -1,8 %, valor próximo ao método físico que alcançou o valor de 21,8 % para o NRMSE e de -3,7 % para o NMB. O método que utiliza a velocidade do vento prevista por redes neurais alcançou o pior resultado de NMB com o valor de -9,4 % e de NRMSE com 22,8 %, porém obteve o melhor resultado referente ao coeficiente de correlação com o valor de 0,74.

Figura 58 - Métricas de performance dos representantes de cada método para o parque Ventos do Sertão.



Conforme já comentado anteriormente, o método físico é considerado como método de referência e as métricas de comparação relativa são mostradas na Tabela 51. O método que emprega redes neurais que prevêem a velocidade do vento resultou em uma piora de -4,6 % para o NMRSE em relação ao do método físico, isto indica que o NRMSE foi 4,6 % maior que o NRMSE obtido pelo método físico. Já para o método que utiliza redes neurais e o aerogerador equivalente médio, houve melhora relativa de 2,0 % em relação ao NRMSE do método de referência. Ambos os métodos apresentaram um coeficiente de correlação melhor do que o para o método físico com uma melhora de 4,2% para o método que prevê a velocidade do vento com redes neurais e de 1,4 % para o método que prevê o aerogerador equivalente com redes neurais. Observando a Figura 58 notamos que o método com redes neurais prevendo à velocidade do vento teve um NMB 2,6 vezes mais distante do dado real quando comparado com o método físico, já o método com redes neurais prevendo o aerogerador equivalente médio ficou mais próximo dos dados reais com uma distância de aproximadamente 0,5 vezes à obtida pelo método de referência.

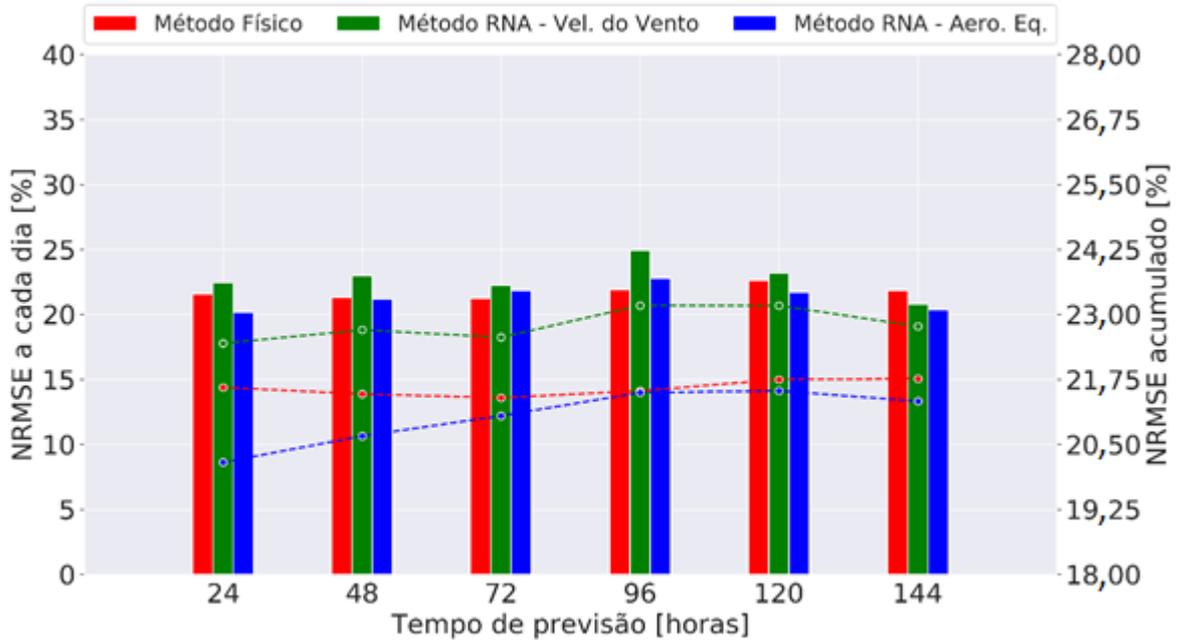
Tabela 51 – Melhora dos modelos com *machine learning* em relação ao método base, método físico, para o parque Ventos do Sertão.

Método	Código	$Imp_{NRMSE}$ [%]	$Imp_r$ [%]

Método de previsão de geração com a velocidade obtida por redes neurais artificiais (Método RNA – Vel. do Vento)	MLP1-Esq_2-GFS-H-1neu	-4,6	4,2
Método de previsão de geração com o aerogerador equivalente médio obtido por redes neurais artificiais (Método RNA – Aero. Eq.)	MLP2-Esq_4-A-5neu	2,0	1,4

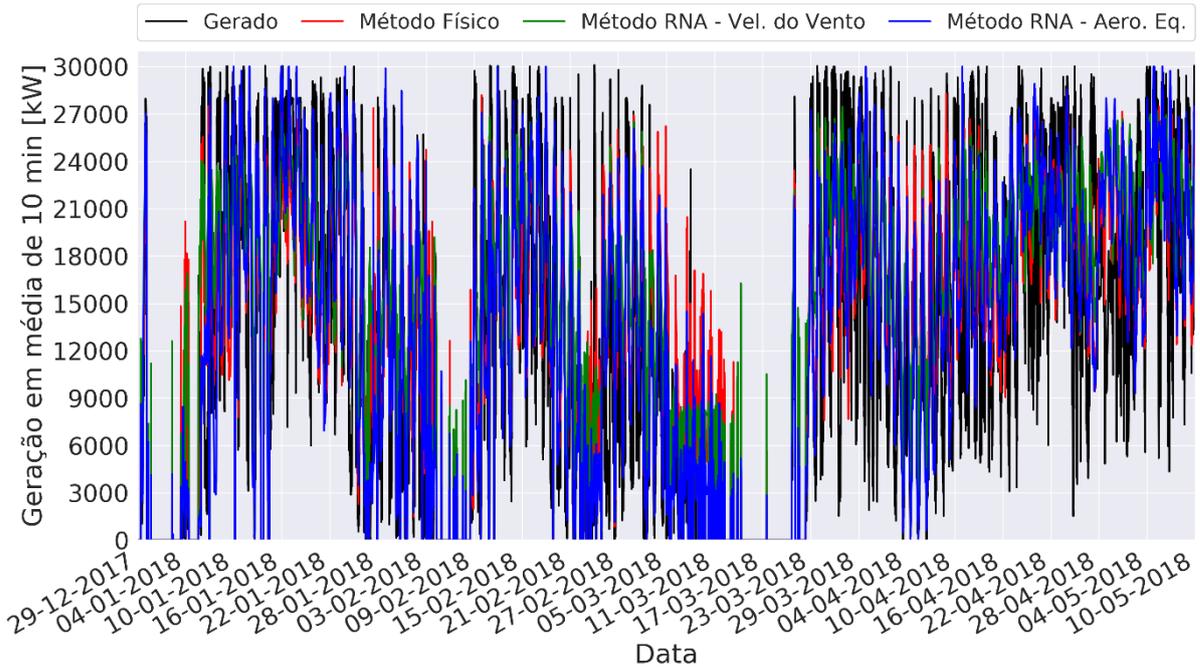
A Figura 59 apresenta o NRMSE calculado para cada dia de previsão, a cada 24 horas, no gráfico de barras e o NRMSE acumulado considerando um horizonte de 24 horas até 144 horas com acréscimos de 24 horas. Lembrando que o horizonte de previsão é de 144 horas (seis dias) com resolução temporal de 10 min. Para o cálculo do NRMSE a cada dia, agruparam-se os dias entre 1 e 6, conforme a distância do momento da realização da previsão e calculou-se o NRMSE para cada conjunto. No NRMSE de cada dia, 24 horas indica o NRMSE do primeiro dia, 48 horas indica o NRMSE do segundo dia e assim por diante. Já o cálculo no NRMSE acumulado considerou-se primeiro um conjunto apenas com o primeiro dia de previsão, 24 horas, depois um conjunto com os dois dias iniciais, 48 horas, ou seja, o NRMSE conforme o aumento do horizonte de previsão. Observa-se que o dia que apresentou maior NRMSE para os métodos com *machine learning* foi o quarto dia indicado por 96 horas, porém o método que prevê a velocidade do vento com redes neurais teve o erro mais proeminente. No método físico o maior NRMSE ocorreu no quinto dia, 120 horas. A tendência é o aumento do erro conforme o aumento do horizonte de previsão, algo que é possível de observar de forma clara com o NRMSE acumulado do método que utiliza o aerogerador equivalente médio. Este comportamento não é tão ressaltado para o parque Ventos do Sertão, em razão das características do local, situado no Nordeste, cujas condições de direção e velocidade do vento são mais estáveis.

Figura 59 - NRMSE calculado a cada dia (gráfico de barras) e NRMSE acumulado conforme o horizonte de previsão aumenta (gráfico de linha) para os diferentes métodos de previsão de geração do parque Ventos do Sertão.



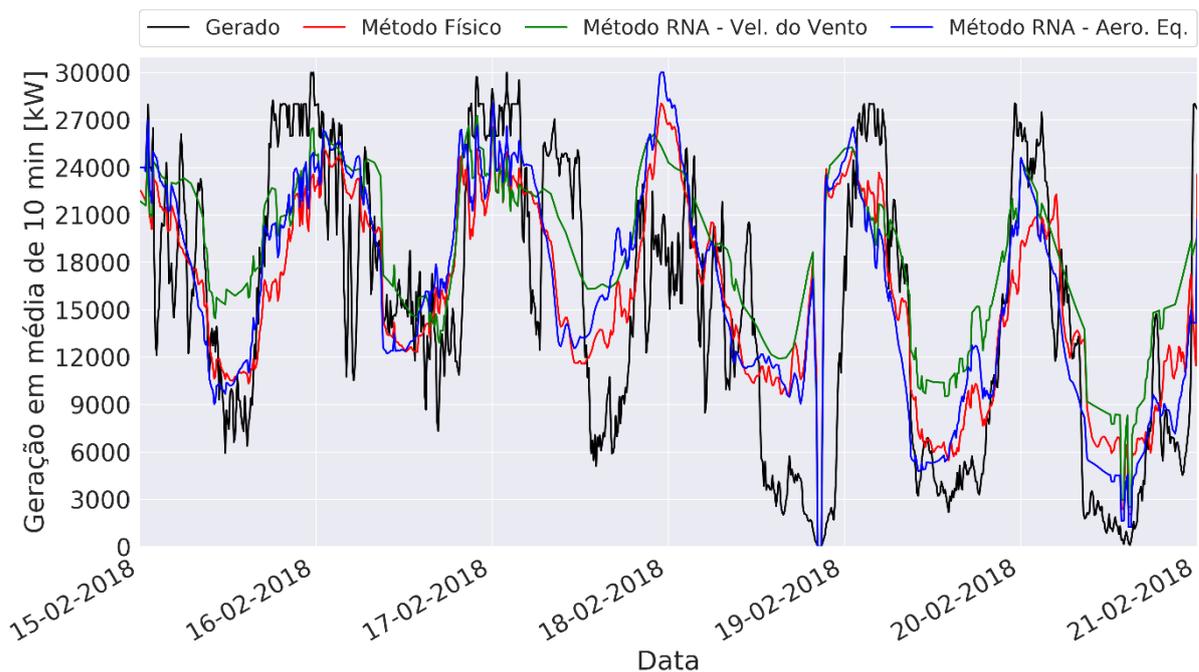
As séries temporais da geração medida e prevista pelos representantes de cada método são apresentadas na Figura 60.

Figura 60 - Séries temporais da geração medida e prevista pelos representantes de cada método para o parque Ventos do Sertão.



Com o intuito de melhorar a percepção com relação à Figura 60, criou-se o gráfico apenas com a previsão do ciclo 8 da Tabela 8, entre 15/02/2018 e o final de 20/02/2018. Observa-se que as previsões pelos diversos métodos acompanharam bem a tendência da geração do parque ao longo das 144 horas, o que também é indicado por terem valores de NRMSE próximos.

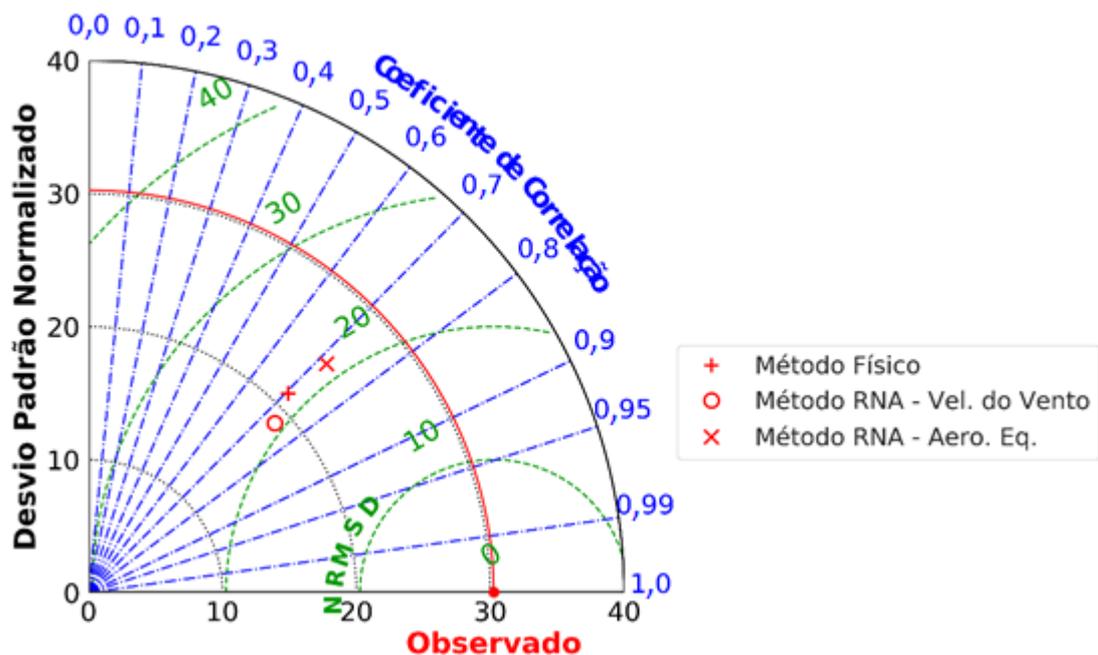
Figura 61 - Geração medida e prevista pelos representantes de cada método para o parque Ventos do Sertão entre o dia 15/02/2018 e o final de 20/02/2018, ciclo 8 da Tabela 8.



A representação estatística pelo diagrama de Taylor dos representantes de cada método de previsão de geração de SER é mostrada na Figura 62. Nota-se que o coeficiente de correlação de todos é próximo à 0,70 e seu NRMSD também é parecido com pequena diferença entre si. Entretanto, há uma grande diferença entre o desvio padrão normalizado, que representa a variabilidade presente no dado. O ponto mais próximo do ponto observado é o do método que utiliza redes neurais para prever a velocidade do vento, porém ele possui a maior distância da variabilidade presente nos dados reais. O método físico ficou mais distante do ponto observado por possuir maior NRMSD e menor coeficiente de correlação. O método que utiliza redes neurais para prever o aerogerador equivalente médio é o segundo ponto mais próximo do observado, porém ele é o que melhor representa a variabilidade, visto que é o que possui o desvio padrão

normalizado mais próximo ao dado observado. Por este motivo considerou-se o método que utiliza o aerogerador equivalente médio como o melhor para o parque Ventos do Sertão.

Figura 62 - Representação estatística pelo diagrama de Taylor dos representantes dos métodos de previsão de geração para o parque Ventos do Sertão.



## Parque Eólico Aura Mirim II

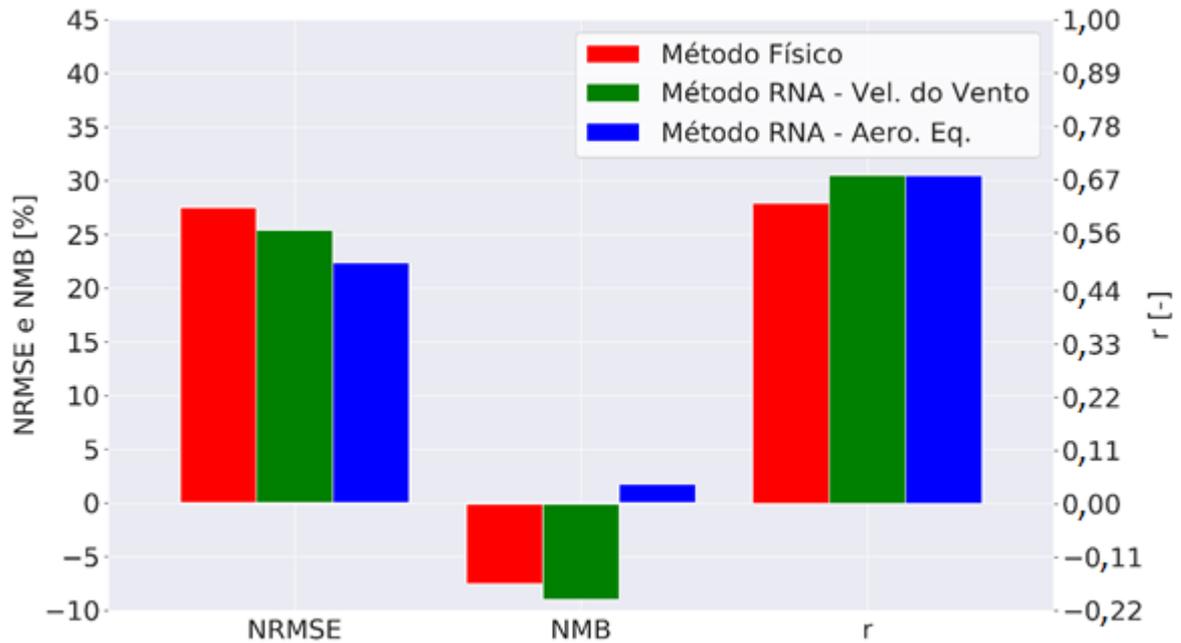
Os representantes de cada método que prevêem a geração do parque Aura Mirim II são apresentados na Tabela 52, juntamente com as métricas de erro. O método físico é representado pelo esquema 1 com a velocidade do vento extraída do modelo global de previsão numérica do tempo GFS. O conjunto de variáveis C foi o melhor para os dois métodos com *machine learning* e em ambos os esquemas são empregadas variáveis de mais de um modelo NWP, simultaneamente. A topologia com uma camada escondida, um neurônio escondido e conjunto de variáveis C no esquema 4 (MLP1-Esq\_4-C-1neu) foi considerado como representante do método que prevê a velocidade do vento com redes neurais. Já o método que prevê o aerogerador com redes neurais tem como representante o esquema 3 com uma rede neural de duas camadas escondidas, cinco neurônios escondidos por camada escondida e conjunto de variáveis C (MLP2-Esq\_3-C-5neu).

Tabela 52 - Representantes de cada método para o parque Aura Mirim II.

<b>Método</b>	<b>Código</b>	<b>NRMSE [%]</b>	<b>NMB [%]</b>	<b>r</b>
Método Físico	GFS	27,5	-7,5	0,62
Método de previsão de geração com a velocidade obtida por redes neurais artificiais (Método RNA – Vel. do Vento)	MLP1-Esq_4-C-1neu	25,4	-9,0	0,68
Método de previsão de geração com o aerogerador equivalente médio obtido por redes neurais artificiais (Método RNA – Aero. Eq.)	MLP2-Esq_3-C-5neu	22,4	1,7	0,68

A Figura 63 mostra, graficamente, as métricas de erro dos representantes de cada método, as quais também são apresentadas na Tabela 52. O menor NRMSE foi de 22,4 % e ocorreu com o método que utiliza o aerogerador equivalente médio. Já o segundo menor foi alcançado pelo método que utiliza a velocidade do vento prevista por redes neurais artificiais. O maior NRMSE foi do método físico. O método físico e o que utiliza redes neurais para prever a velocidade do vento tiveram valores de NMB negativos e próximos entre si. O menor valor de NMB ocorreu com o método que prevê o aerogerador equivalente médio com redes neurais e teve o valor de 1,7 %. O coeficiente de correlação de Pearson de 0,68 foi o maior valor e o mesmo foi alcançado por ambos métodos de previsão de geração do parque que empregam *machine learning*.

Figura 63 - Métricas de performance dos representantes de cada método para o parque Aura Mirim II.



A comparação entre os métodos com *machine learning* em relação ao método de referência, que é o método físico, é apresentada na Tabela 53. Ambos os métodos apresentaram melhora em relação ao método físico para o NRMSE e o coeficiente de correlação de Pearson correspondentes. O NRMSE foi 7,6 % menor para o método que utiliza redes neurais para prever a velocidade do vento; e 18,8 % menor para o método que prevê o aerogerador equivalente. A melhora em r foi a mesma para os dois métodos com *machine learning*, que obtiveram um coeficiente de correlação 9,7 % maior que o obtido pelo método de referência. O valor de NMB do método que prevê a geração com a velocidade do vento prevista por uma rede neural foi pior que o do método físico, com o valor de 1,2 vezes a distância do método de referência. O método que emprega o aerogerador equivalente alcançou o menor valor de NMB, que equivale a 0,2 vezes a distância do método físico em relação ao dado real.

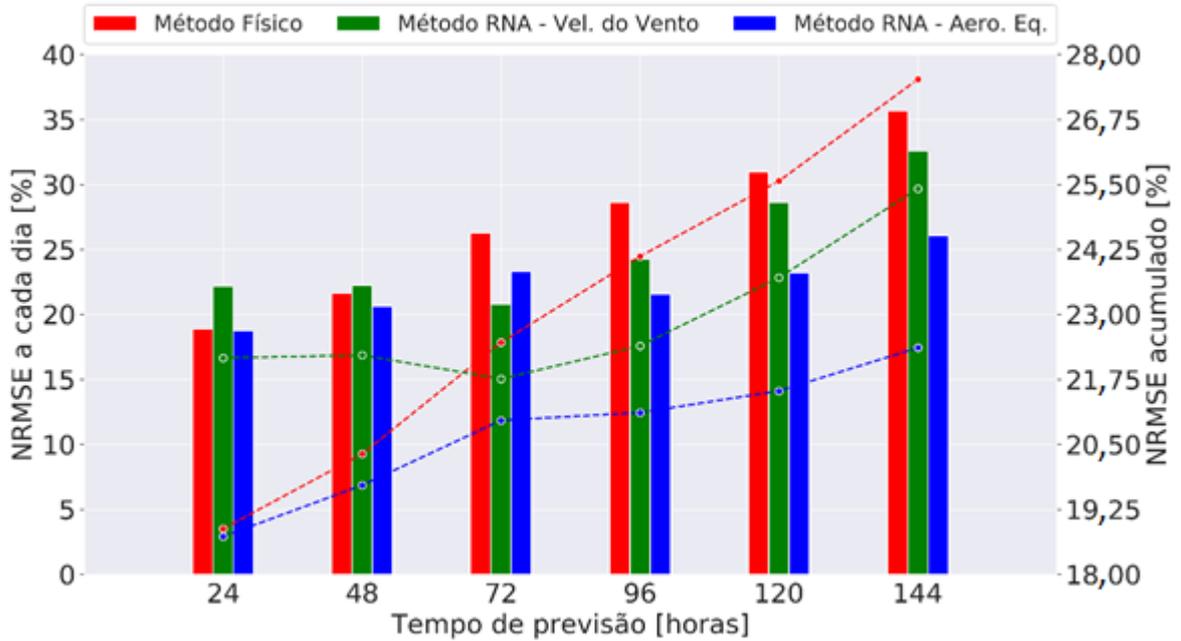
Tabela 53 – Melhora dos modelos com *machine learning* em relação ao método base, método físico, para o parque Aura Mirim II.

Método	Código	$Imp_{NRMSE}$ [%]	$Imp_r$ [%]
Método de previsão de geração com a velocidade obtida por redes neurais artificiais	MLP1-Esq_4-C-1neu	7,6	9,7

(Método RNA – Vel. do Vento)			
Método de previsão de geração com o aerogerador equivalente médio obtido por redes neurais artificiais (Método RNA – Aero. Eq.)	MLP2-Esq_3-C-5neu	18,8	9,7

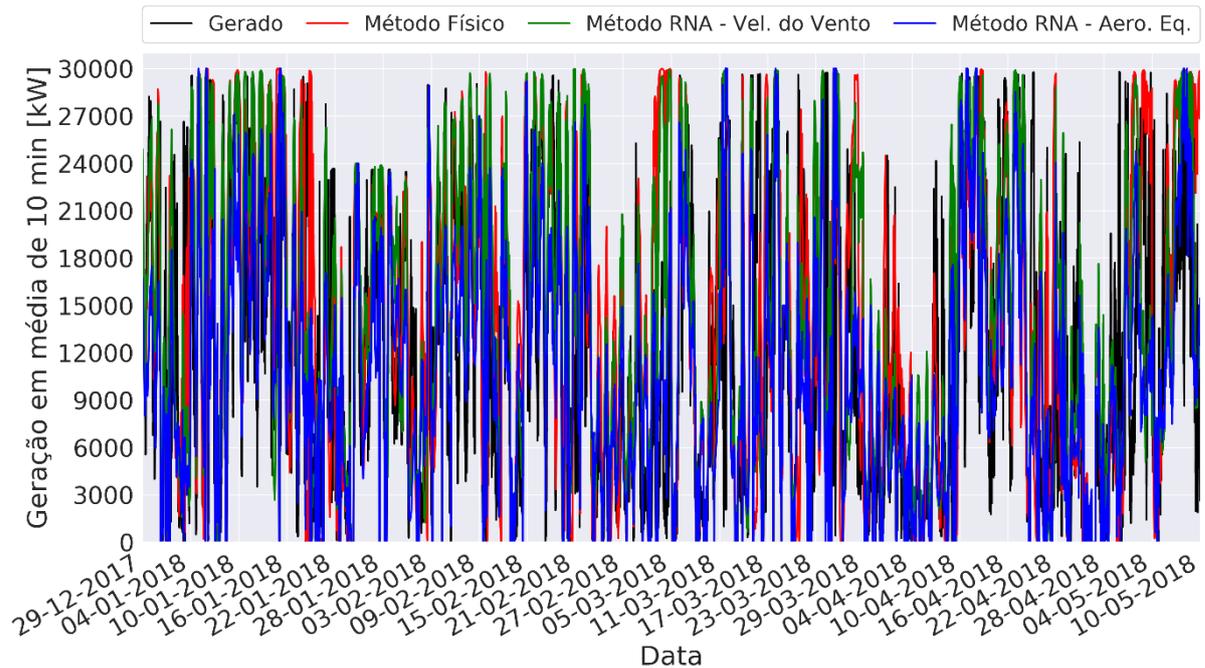
O NRMSE para cada dia e o acumulado no horizonte de previsão são mostrados para as 144 horas de previsão do parque Aura Mirim II na Figura 64. O dia com maior NRMSE foi o sexto dia, 144 horas, para todos os métodos. Conforme o horizonte de previsão aumenta o erro de previsão aumenta, o que é proeminente e observado em todos os métodos no NRMSE acumulado. O método que possui o aumento mais expressivo à medida que se aumenta o horizonte de previsão é o método físico, já os métodos com *machine learning* obtiveram um aumento menos acentuado, que pode ser explicado pelo fato de as redes neurais utilizarem esquemas com variáveis de entrada de mais de um modelo de previsão numérica do tempo no parque Aura Mirim II. O local do parque Aura Mirim II é suscetível a eventos extremos, tais como passagem de frentes frias, o que pode ser responsável pelo maior aumento do erro com o aumento do horizonte de previsão.

Figura 64 - NRMSE calculado a cada dia (gráfico de barras) e NRMSE acumulado conforme o horizonte de previsão aumenta (gráfico de linha) para os diferentes métodos de previsão de geração do parque Aura Mirim II.



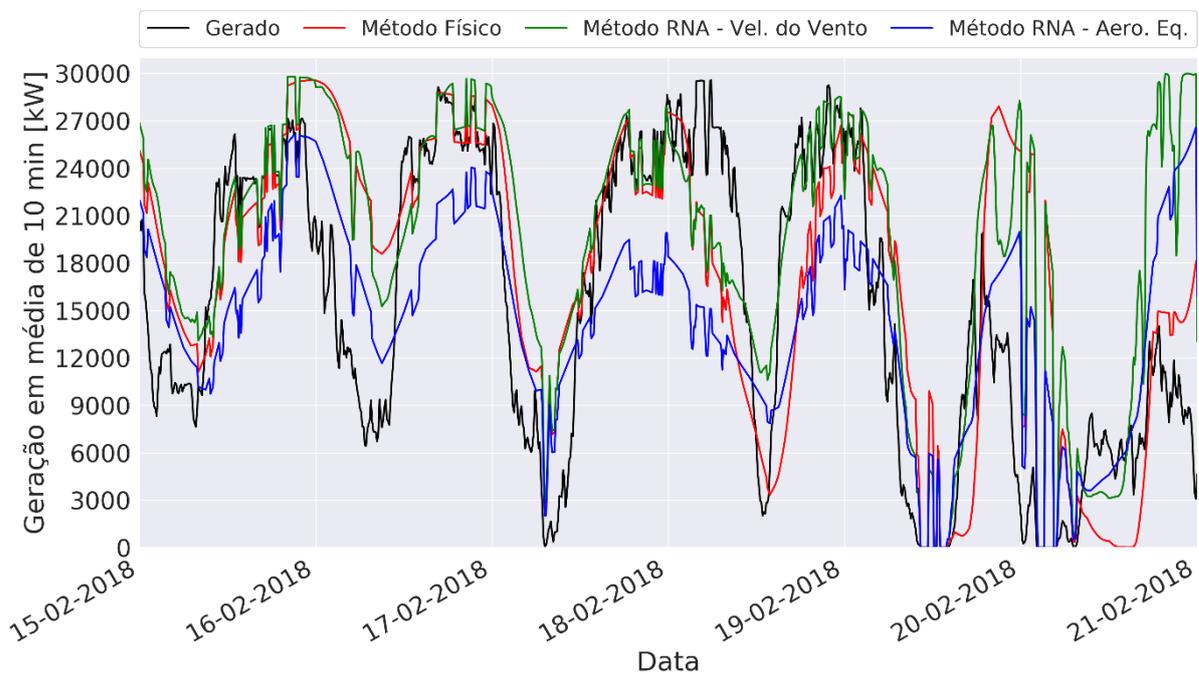
A geração real e a prevista pelos representantes de cada método para o parque de Aura Mirim II são mostradas na Figura 65.

Figura 65 - Séries temporais da geração medida e prevista pelos representantes de cada método para o parque Aura Mirim II.



O período de previsão de geração do parque Aura Mirim II entre o dia 15/02/2018 e o final do dia 20/02/2018, ciclo 8 da Tabela 8, é apresentado na Figura 66. Nota-se que nesta previsão todos os métodos acompanham a tendência da geração do parque, porém no último dia o erro aumenta, o que é coerente com o aumento do erro de previsão ao longo do horizonte de previsão visto anteriormente. Aparentemente, na previsão do ciclo 8, o método físico e o que prevê a velocidade do vento com redes neurais representam melhor a variabilidade dos dados.

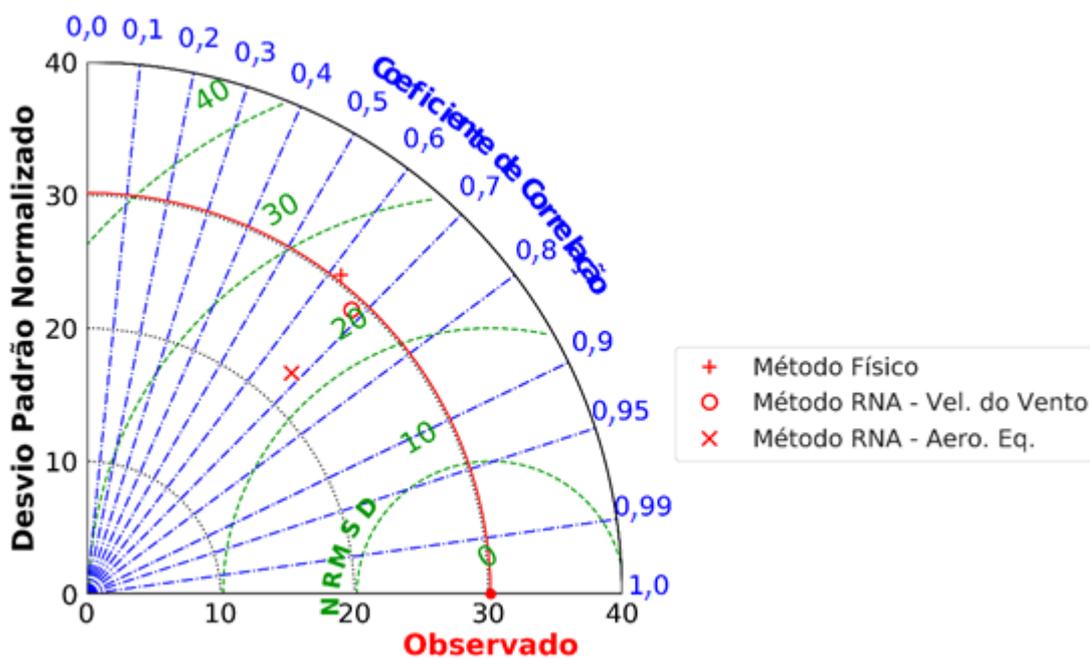
Figura 66 - Geração medida e prevista pelos representantes de cada método para o parque Aura Mirim II entre o dia 15/02/2018 e o final de 20/02/2018, ciclo 8 da Tabela 7.



A Figura 67 apresenta o diagrama de Taylor para os métodos de previsão de geração do parque Aura Mirim II. Nota-se que o método físico e o método com redes neurais que prevêem a velocidade do vento são os mais próximos do desvio padrão normalizado dos dados reais, por isso representam melhor a variabilidade presente nos dados medidos. O ponto mais próximo do ponto observado é o do método que emprega redes neurais com o aerogerador equivalente médio, porém este método apresenta o desvio padrão normalizado mais distante dos dados reais. Os métodos com *machine learning* apresentam o mesmo valor para o coeficiente de correlação de Pearson. O método físico resultou no ponto mais distante do ponto observado, indicando que seria o menos apto a representar os dados reais. Apesar de o método que

utiliza o aerogerador equivalente médio não representar tão bem a variabilidade presente nos dados reais, este método resultou no ponto mais próximo do ponto observado e possui o menor valor de NRMSE e NMB, como se pode observar, na Tabela 52. Por este motivo, o método com redes neurais e o aerogerador equivalente é considerado o que melhor prevê a geração do parque Aura Mirim II.

Figura 67 - Representação estatística pelo diagrama de Taylor dos representantes dos métodos de previsão de geração para o parque Aura Mirim II.



## 5 CONCLUSÕES E RECOMENDAÇÕES

### 5.1 CONCLUSÕES

Nesta pesquisa, foram feitas diferentes abordagens de previsão de geração eólica, com horizonte de 144 horas (seis dias) e resolução temporal de 10 min, para dois parques eólicos, localizados no Nordeste e no extremo Sul do Brasil. O parque Ventos do Sertão (SER) possui 15 aerogeradores de 2 MW e faz parte do Complexo Eólico de Morrinhos (CEMOR), localizado no interior da Bahia. O parque Aura Mirim II (MIR-2) possui 10 aerogeradores de 3 MW e faz parte do Complexo Eólico de Santa Vitória do Palmar (CESVP), localizado no litoral do extremo Sul do Rio Grande do Sul. Cada parque possui 30 MW de capacidade instalada e estão a aproximadamente 2800 km de distância um do outro, nas duas regiões com maior potencial de energia eólica brasileiro. Os dados utilizados neste trabalho englobam o período entre 23/12/2017 e 09/05/2018, totalizando 138 dias.

Três abordagens de previsão de geração foram empregadas: o método físico, com o emprego da velocidade do vento interpolada diretamente do modelo de previsão numérica do tempo (NWP) na curva de potência do fabricante do aerogerador; o método com *machine learning* em que a rede neural artificial previa a velocidade do vento, a qual era utilizada na curva de potência do fabricante do aerogerador; e o método com *machine learning* em que o aerogerador equivalente médio era previsto pela rede neural artificial. De acordo com a revisão bibliográfica realizada, não foram encontrados resultados de análises de previsão com horizontes temporais extensivos quanto o da presente pesquisa.

O parque Aura Mirim II apresenta muitos eventos extremos com picos de velocidade de até 25,00 m/s, como verificado na série temporal de velocidade. Ciclones extratropicais, por exemplo, são fenômenos que afetam a região costeira do Sul do Brasil. Comparando o comportamento da série temporal da velocidade do vento, observa-se que MIR-2 possui muito mais variabilidade do que o parque SER. O modelo de mesoescala WRF foi eficaz na previsão de velocidade para o parque Ventos do Sertão, algo que era esperado por se tratar de um terreno complexo e a literatura informar que o mesmo ocorre. No caso do parque Aura Mirim II, a velocidade do vento foi melhor prevista pelos modelos globais, visto que o terreno é simples. Analisando os resultados de previsão de velocidade diretamente obtida dos modelos NWP, o

parque MIR-2 se mostrou mais difícil de prever. A região do Complexo Eólico de Morrinhos apresenta um comportamento mais constante devido à forte influência dos ventos alísios enquanto a região do Complexo Eólico de Santa Vitória do Palmar não possui um padrão definido por sofrer com tempestades e a passagem de frentes frias.

Para ambos os parques foi possível notar a ocorrência do *overfitting* para alguns conjuntos de variáveis e geralmente nas RNAs com maior número de camadas escondidas. Isto pode ter sido mais intenso nas topologias com duas e três camadas pelo fato das mesmas apresentarem maior capacidade de abstração e tirar informações de padrões que ocorreram apenas durante o treinamento. É notável nas topologias com mais de uma camada escondida que geralmente cinco neurônios escondidos por camada já eram suficientes para aprender os padrões que ocasionavam a melhor generalização.

A seleção de variáveis pelo método de filtro com correlação de Pearson não foi tão eficiente, pois não apresentou em nenhum momento o melhor resultado dentre os esquemas que empregavam os métodos com uso de *machine learning*. Porém, nota-se que SER possui mais correlação linear com as variáveis de entrada do que MIR-2, pois há um maior número de variáveis selecionadas por este método de seleção de variáveis para o parque Ventos do Sertão. As variáveis selecionadas por este método de filtro compunham um dos nove conjuntos de variáveis testados nas diferentes topologias de RNA. Os conjuntos de variáveis A (velocidade na altura do cubo ou no nível mais próximo) e C (velocidade na altura do cubo ou no nível mais próximo, hora decimal e tempo de simulação) foram os que mais apareceram para os esquemas com *machine learning* para o parque Aura Mirim II. Já para o parque Ventos do Sertão foram os conjuntos B (velocidade do vento mais próxima ou na altura do cubo e hora decimal) e F (componente U e V da velocidade do vento mais próxima ou na altura do cubo e hora decimal).

As métricas de erro, assim como os diagramas de Taylor para a abordagem física de previsão de geração de ambos os parques mostram que cada modelo NWP tem um comportamento distinto dos demais. As abordagens com *machine learning* para os diversos esquemas de previsão do parque Ventos de Sertão mostraram resultados muito próximos, o que pode ser visto com os valores de erro com pouca diferença e pelos pontos concentrados nos seus diagramas de Taylor. No caso do parque Aura Mirim II, há uma maior diferença na performance dos esquemas que empregam as abordagens com *machine learning*, visto que há dispersão dos pontos nos diagramas de Taylor e há uma maior diferença entre as métricas de performance de cada esquema. Entretanto, os esquemas 3 e 4 sempre se situaram próximos ao ponto observado nos diagramas de Taylor para ambos os parques, o que mostra o benefício da utilização de diferentes

modelos de previsão numérica do tempo simultaneamente. Lembrando que o esquema 3 utiliza variáveis do GFS e GDPS enquanto o esquema 4 variáveis do GFS, GDPS e WRF na grade d01 com 12 km de resolução espacial.

A topologia da rede neural se repetiu para os dois parques em cada uma das abordagens que empregou *machine learning* se diferenciando apenas no conjunto de dados de entrada. Os melhores representantes para o método que prevê com redes neurais a velocidade na posição da torre de referência foi aquele com uma camada escondida e um neurônio escondido. Para o método que prevê o aerogerador equivalente médio com redes neurais, a melhor topologia foi com duas camadas escondidas e cinco neurônios por camada escondida. O parque Ventos do Sertão teve o esquema 2 com o conjunto de variáveis H do GFS como o melhor para a rede neural que prevê a velocidade do vento e o esquema 4 com conjunto de variáveis A como o melhor para a rede neural que prevê o aerogerador equivalente médio. Para o parque Aura Mirim II, o esquema 4 com o conjunto de variáveis C foi o melhor para o método que emprega a RNA para prever a velocidade do vento e o esquema 3 com o conjunto de variáveis C para a RNA do método que utiliza o aerogerador equivalente médio.

Como era de se esperar, o erro aumenta com o horizonte de previsão para os dois parques, porém isto foi mais proeminente para o parque MIR-2. No parque Ventos do Sertão, o método com *machine learning* que prevê a velocidade do vento apresentou um NRMSE 4,6 % maior em relação ao do método físico, o que indica uma piora, porém o coeficiente de correlação de Pearson ( $r$ ) ficou 4,2 % maior que o método base, o que representa uma melhora; já o método baseado no aerogerador equivalente resultou em uma melhora de 2,0 % no NRMSE e de 1,4 % no  $r$ . Ambos os modelos com aprendizado de máquina apresentaram melhora em relação ao método físico para Aura Mirim II. O método que prevê a velocidade do vento com RNA alcançou um NRMSE 7,6 % melhor enquanto o método que prevê o aerogerador equivalente apresentou uma melhora de 18,8 % no NRMSE. Ambos os métodos com *machine learning* melhoraram o coeficiente de correlação de Pearson em 9,7 % no parque de Aura Mirim II em relação ao método de referência. O melhor resultado para previsão de geração para o parque Ventos do Sertão e Aura Mirim II foi o mesmo, este, segundo análise, foi o método com *machine learning* que aplica redes neurais prevendo a geração do aerogerador equivalente médio.

O NRMSE da previsão de geração do parque com o método com o aerogerador equivalente médio foi de 21,33 % para Ventos do Sertão e 22,36 % para Aura Mirim II. Estes valores

são para o horizonte de previsão de 144 horas (seis dias) com resolução temporal de 10 min. Na literatura, não há artigos que mostram resultados com horizontes de previsão desta extensão, no entanto, Giebel e Kariniotakis (2017) indicam que o NRMSE fica entre 9 e 14 % para previsões com horizonte de 24 horas à frente e Monteiro et al. (2009) que o NRMSE fica entre 14 e 17 % para o horizonte de 48 horas adiante. Os valores de NRMSE obtidos neste trabalho ficaram acima dos citados por Giebel e Kariniotakis (2017) e Monteiro et al. (2009), porém o horizonte de previsão, na presente pesquisa, é três vezes maior.. Um ponto importante é que todos os métodos de previsão mostraram acompanhar a tendência da geração do parque, algo que segundo Moehrlen et al. (2019) geralmente é o foco de previsões com horizonte de previsão de sete dias.

## 5.2 SUGESTÕES PARA TRABALHOS FUTUROS

Sugerem-se os tópicos abaixo para trabalhos futuros:

- Utilizar o GDPS como condições iniciais e de contorno para o WRF;
- Desenvolver previsões de geração probabilísticas;
- Estender a metodologia para mais parques;
- Testar outros algoritmos de *machine learning*;
- Avaliar outros períodos (por exemplo, inverno);
- Inserir assimilação de dados no modelo WRF;
- Alterar o tamanho dos domínios para o parque eólico Aura Mirim II, considerando que é uma região afetada por ciclones extratropicais;
- Testar novas parametrizações físicas no WRF para os parques eólicos deste trabalho.

## REFERÊNCIAS

ALESSANDRINI, S. et al. An application of ensemble/multi model approach for wind power production forecasting. **Advances in Science and Research**, v. 6, n. 1, p. 35–37, 2011.

ALESSANDRINI, S.; SPERATI, S.; PINSON, P. A comparison between the ECMWF and COSMO Ensemble Prediction Systems applied to short-term wind power forecasting on real data. **Applied Energy**, v. 107, p. 271–280, 2013.

ANEEL. **BIG - Banco de Informações de Geração**. Disponível em: <<http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.cfm>>. Acesso em: 5 dez. 2019.

ARTIPOLI, G.; DURANTE, F. Physical Modeling in Wind Energy Forecasting. **Dewi Magazin**, n. 44, p. 10–15, 2014.

BURTON, T. et al. **Wind Energy Handbook, Second Edition**. 2nd editio ed. Chichester, UK: John Wiley & Sons, Ltd, 2011.

CALI, Ü. et al. Artificial neural network based wind power forecasting using a multischeme ensemble prediction model. **European Wind Energy Conference and Exhibition 2008**, v. 1, n. January, 2008.

CANADIAN METEOROLOGICAL CENTRE. **Site com os dados do GDPS 25 km**. Disponível em: <[https://dd.weather.gc.ca/model\\_gem\\_global/25km/](https://dd.weather.gc.ca/model_gem_global/25km/)>. Acesso em: 28 out. 2019.

CATALÃO, J. P. S.; POUSINHO, H. M. I.; MENDES, V. M. F. Short-term wind power forecasting in Portugal by neural networks and wavelet transform. **Renewable Energy**, v. 36, n. 4, p. 1245–1251, 2011.

CHANG, W.-Y. A Literature Review of Wind Forecasting Methods. **Journal of Power and Energy Engineering**, v. 02, n. 04, p. 161–168, 2014.

CHOLLET, F. **Deep Learning with Python**. Shelter Island, NY: Manning Publications Co., 2018.

CMC. **GDPS data in GRIB2 format: 25 km**. Disponível em: <[https://weather.gc.ca/grib/grib2\\_glb\\_25km\\_e.html](https://weather.gc.ca/grib/grib2_glb_25km_e.html)>. Acesso em: 28 out. 2019.

COIFFIER, J. **Fundamentals of Numerical Weather Prediction**. Cambridge, UK: Cambridge University Press, 2011.

CORINNA, C. M. et al. **Recommended Practices for Selecting Renewable Power Forecasting Solutions - Part 1: Forecast Solution Selection Process**. [s.l: s.n.]. Disponível em:

<[https://www.researchgate.net/publication/336022217\\_Recommended\\_Practice\\_on\\_Renewable\\_Energy\\_Forecast\\_Solution\\_Selection](https://www.researchgate.net/publication/336022217_Recommended_Practice_on_Renewable_Energy_Forecast_Solution_Selection)>.

FARIAS, J. G. DE et al. **Previsão de Geração no Médio Prazo em um Parque Eólico no Rio Grande do Sul utilizando o GFS e Redes Neurais Artificiais**. Brazil Windpower 2019: Artigos Trabalhos Técnicos. **Anais...**2019

FENG, C. et al. A data-driven multi-model methodology with deep feature selection for short-term wind forecasting. **Applied Energy**, v. 190, p. 1245–1257, 2017.

FOKEN, T. **Micrometeorology**. Berlin Heidelberg, DE: Springer, 2008.

FOLEY, A. M. et al. Current methods and advances in forecasting of wind power generation. **Renewable Energy**, v. 37, n. 1, p. 1–8, 1 jan. 2012.

FUCK, V. R. **Tratamento de dados eólicos e avaliação da velocidade do vento com o uso de perfilador LiDAR**. [s.l.] Universidade Federal de Santa Catarina, 2016.

GÉRON, A. **Hands-on Machine Learning with Scikit-Learn, Keras and Tensorflow**. Sebastopol, USA: O'Reilly Media, 2017.

GIEBEL, G. et al. **The State of the Art in Short-Term Prediction of Wind Power: A Literature Overview, 2nd Edition**. Roskilde, DK: [s.n.].

GIEBEL, G.; KARINIOTAKIS, G. **Chapter 3: Wind power forecasting - a review of the state of the art**. Cambridge, UK: Elsevier Ltd, 2017.

GIORGI, M. G. DE; FICARELLA, A.; TARANTINO, M. Assessment of the benefits of numerical weather predictions in wind power forecasting based on statistical methods. **Energy**, v. 36, n. 7, p. 3968–3978, 2011.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge, USA: MIT Press, 2016.

GWEC. **GLOBAL WIND REPORT - Annual Market Update 2017**. [s.l: s.n.]. Disponível em: <<http://files.gwec.net/register?file=/files/GWR2017.pdf>>.

HAU, E. **Wind Turbines: Fundamentals, Technologies, Application, Economics**. 2nd editio ed. [s.l.] Springer, 2006.

HAYKIN, S. **Neural Networks and Learning Machines**. Third Edit ed. [s.l.] Pearson Education, Inc., 2009.

HEATON, J. **Artificial Intelligence for Humans, Volume 1: Fundamental**

**Algorithms.** Chesterfield, MO: Heaton Research, Inc., 2013.

HEATON, J. **Artificial Intelligence for Humans - Volume3: Deep Learning and Neural Networks.** Chesterfield, MO: Heaton Research, Inc., 2015.

HINTON, G.; OSINDERO, S.; TEH, Y.-W. A fast learning algorithm for deep belief nets. **Neural computation**, 2006.

HYNDMAN, R.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice, 2nd Edition.** 2nd Editio ed. [s.l.] Otexts, 2018.

JACOBSON, M. Z. **Fundamentals of Atmospheric Modeling.** Second Edi ed. [s.l.] Cambridge University Press, 2005.

JAIN, P. **Wind Energy Engineering.** New York: Mc Graw Hill, 2011.

JUNG, J.; BROADWATER, R. P. Current status and future advances for wind speed and power forecasting. **Renewable and Sustainable Energy Reviews**, v. 31, p. 762–777, 2014.

KHOSRAVI, A.; MACHADO, L.; NUNES, R. O. Time-series prediction of wind speed using machine learning algorithms: A case study Osorio wind farm, Brazil. **Applied Energy**, v. 224, n. April, p. 550–566, 2018.

LANGE, M.; FOCKEN, U. **State-of-the-Art in Wind Power Prediction in Germany and International.** Proceedings of the second workshop of international feed-in cooperation. **Anais...Berlin: 2005**Disponível em: <[https://www.researchgate.net/publication/237677945\\_State-of-the-Art\\_in\\_Wind\\_Power\\_Prediction\\_in\\_Germany\\_and\\_International\\_Developments](https://www.researchgate.net/publication/237677945_State-of-the-Art_in_Wind_Power_Prediction_in_Germany_and_International_Developments)>

LANGE, M.; HEINEMANN, D. **Accuracy of short term wind power prediction depending on meteorological conditions.** Proceedings of the 2002 Global Windpower Conference. **Anais...2002 Global Windpower Conference, 2002**Disponível em: <[https://uol.de/fileadmin/user\\_upload/physik/ag/ehf/enmet/publications/wind/conference/2002/gwc\\_paris/Accuracy\\_of\\_short\\_term\\_wind\\_power\\_predictions\\_dependig\\_on\\_meteorologic\\_al\\_conditions.pdf](https://uol.de/fileadmin/user_upload/physik/ag/ehf/enmet/publications/wind/conference/2002/gwc_paris/Accuracy_of_short_term_wind_power_predictions_dependig_on_meteorologic_al_conditions.pdf)>

LANGE, M.; HEINEMANN, D. **Relating the uncertainty of short-term wind speed prediction to meteorological situations.** Proceedings of the 2003 european wind energy conference and exhibition. **Anais...2003**

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, p. 436–444, 2015.

LI, S. et al. Using neural networks to estimate wind turbine power generation. **IEEE Transactions on Energy Conversion**, v. 16, n. 3, p. 276–282, 2001.

LIU, H. et al. A hybrid statistical method to predict wind speed and wind power. **Renewable Energy**, v. 35, n. 8, p. 1857–1861, 2010.

LIU, H. et al. A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks. **Renewable Energy**, v. 48, p. 545–556, 2012.

LYDIA, M.; SURESH KUMAR, S. A comprehensive overview on wind power forecasting. **2010 9th International Power and Energy Conference, IPEC 2010**, p. 268–273, 2010.

LYNCH, P. **The Emergence of Scientific Weather Forecasting: Richardson's Dream**. 1 edition ed. [s.l.] Cambridge University Press, 2006.

MANWELL, J. F.; MCGOWAN, J. G.; ROGERS, A. L. **Wind Energy Explained: Theory, Design and Application**. 2nd edition ed. [s.l.] John Wiley & Sons Ltd, 2009.

MARTI, I. et al. **Evaluation of Advanced Wind Power Forecasting Models – Results of the Anemos Project**. European Wind Energy Conference, EWEC 2006. **Anais...Athènes, Greece: European Wind Energy Conference, 2006**

MARTÍN-VÁZQUEZ, R.; ALER, R.; GALVÁN, I. M. **Wind energy forecasting at different time horizons with individual and global models** (M. I., I. L., P. V., Eds.) **14th IFIP WG 12.5 International Conference on Artificial Intelligence Applications and Innovations, AIAI 2018** EVANNAI, Carlos III University of Madrid, Avda. Universidad, 30, Leganés, 28911, Spain Springer New York LLC, , 2018.

MCAVANEY, B. J. et al. Model evaluation. In: **Climate Change 2001: The Scientific Basis**. Cambridge, United Kingdom and New York, NY, USA: Cambridge University Press, 2001.

MINISTÉRIO DE MINAS E ENERGIA (MME); EMPRESA DE PESQUISA ENERGÉTICA (EPE). **Plano Decenal de Expansão de Energia 2027**. Brasília: [s.n.].

MOHAMMED, M.; KHAN, M. B.; BASHIER, E. B. M. **Machine Learning Algorithms and Applications**. [s.l.] CRC Press, 2017.

MÖHRLÉN, C. **Uncertainty in wind energy forecasting**. [s.l.] University College Cork, 2004.

MONTEIRO, C. et al. **Wind power forecasting : state-of-the-art 2009**. Oak Ridge, TN, USA: [s.n.]. Disponível em: <<http://www.osti.gov/servlets/purl/968212-IMKXCO/>>.

MORENO, P. et al. **Short-term wind forecast** Madrid, ESEuropean Wind Energy

Conference and Exhibition, , 2003.

NASCIMENTO, P. S. DE C. et al. **Modelo Adaptativo de Previsão de Geração de Fonte Eólica para o Tempo Real**. Brazil Windpower Conference and Exhibition. **Anais...**Rio de Janeiro: Brazil Windpower 2018, 2018

NCEP. **Global Forecast System**. Disponível em: <<https://www.emc.ncep.noaa.gov/GFS/doc.php>>. Acesso em: 28 out. 2019.

**NCEP GFS 0.25 Degree Global Forecast Grids Historical Archive**. Boulder, CO Research Data Archive at the National Center for Atmospheric Research, Computational and Information Systems Laboratory, , 2015. Disponível em: <<https://doi.org/10.5065/D65D8PWK>>

NOAA. **NOAA Operational Model Archive and Distribution System (NOMADS)**. Disponível em: <<https://nomads.ncep.noaa.gov>>. Acesso em: 28 out. 2019.

ONS. **Submódulo 8.1 - Programação diária da operação eletroenergética Brasil**, 2016. Disponível em: <[http://www.ons.org.br/paginas/download.aspx?vig=1&SourceUrl=%2FProcedimentosDeRede%2FMódulo 8](http://www.ons.org.br/paginas/download.aspx?vig=1&SourceUrl=%2FProcedimentosDeRede%2FMódulo%208)>

PIELKE, R. A. **Mesoscale Meteorological Modeling, Volume 78, Second Edition (International Geophysics)**. Second Edi ed. [s.l.] Academic Press, 2002.

PINSON, P.; KARINIOTAKIS, G. On-line Assessment of Prediction Risk for Wind Power Production Forecasts. **Wind Energy**, 2004.

PRUSOV, V.; DOROSHENKO, A. **Computational Techniques for Modeling Atmospheric Processes**. [s.l.] IGI Global, 2018.

RUSSEL, S.; NORVIG, P. **Artificial Intelligence: A Mordern Approach**. Third Edit ed. [s.l.] Pearson Education, Inc., 2010.

SALCEDO-SANZ, S. et al. Accurate short-term wind speed prediction by exploiting diversity in input data using banks of artificial neural networks. **Neurocomputing**, v. 72, n. 4–6, p. 1336–1341, 2009.

SALCEDO-SANZ, S. et al. Feature selection in machine learning prediction systems for renewable energy applications. **Renewable and Sustainable Energy Reviews**, v. 90, n. December 2016, p. 728–741, 2018.

SERGIO, A. T.; LUDERMIR, T. B. Deep learning for wind speed forecasting in

northeastern region of Brazil. **Proceedings - 2015 Brazilian Conference on Intelligent Systems, BRACIS 2015**, n. D1, p. 322–327, 2015.

SKAMAROCK, W. C. et al. **A Description of the Advanced Research WRF Version 3 (No. NCAR/TN-475+STR)NCAR TECHNICAL NOTE**. [s.l: s.n.].

STENSRUD, D. J. **Parameterization Schemes: Keys to Understanding Numerical Weather Prediction Models**. [s.l.] Cambridge University Press, 2007.

STULL, R. B. **An introduction to boundary layer meteorology**. [s.l: s.n.]. v. 8

TAYLOR, K. E. Summarizing multiple aspects of model performance in a single diagram. **Journal of Geophysical Research: Atmospheres**, v. 106, n. D7, p. 7183–7192, 16 abr. 2001.

TOOK, C. C. et al. Quaternion-valued short-term joint forecasting of three-dimensional wind and atmospheric parameters. **Renewable Energy**, v. 36, n. 6, p. 1754–1760, 2011.

USAOLA, J. et al. Benefits for Wind Energy in Electricity Markets from Using Short Term Wind Power Prediction Tools ; a Simulation Study. **Wind Engineering**, v. 28, p. 119–128, 2004.

VACCARO, A. et al. An adaptive framework based on multi-model data fusion for one-day-ahead wind power forecasting. **Electric Power Systems Research**, v. 81, n. 3, p. 775–782, 2011.

VARGAS, S. A. et al. Wind power generation : A review and a research agenda. **Journal of Cleaner Production**, v. 218, p. 850–870, 2019.

VON BREMEN, L. Combination of deterministic and probabilistic meteorological models to enhance wind farm power forecasts. **Journal of Physics: Conference Series**, v. 75, n. 1, 2007.

WANG, H.-Z. et al. Deep learning based ensemble approach for probabilistic wind power forecasting. **Applied Energy**, v. 188, p. 56–70, 2017.

WANG, X.; GUO, P.; HUANG, X. A review of wind power forecasting models. **Energy Procedia**, v. 12, p. 770–778, 2011.

WANG, Y.; WANG, J.; WEI, X. A hybrid wind speed forecasting model based on phase space reconstruction theory and Markov model : A case study of wind farms in northwest China. **Energy**, v. 91, p. 556–572, 2015.

WARNER, T. T. **Numerical Weather and Climate Prediction**. [s.l.] Cambridge University Press, 2011.

ZHANG, J. et al. A hybrid method for short-term wind speed forecasting. **Sustainability**, v. 9, n. 4, p. 1–10, 2017.

ZHAO, P. et al. Performance evaluation and accuracy enhancement of a day-ahead wind power forecasting system in China. **Renewable Energy**, v. 43, p. 234–241, 2012.

## APÊNDICE A – Coordenadas dos aerogeradores

Nas Tabela A1 e A2, são fornecidas as coordenadas geográficas e altitude de cada aerogerador e da torre de medição dos Parques Eólicos Aura Mirim II e Ventos do Sertão, respectivamente.

Tabela A1 - Posição geográfica e altitude dos aerogeradores e torre de referência do parque eólico Aura Mirim II.

<b>ID</b>	<b>Altitude [m]</b>	<b>Latitude [°]</b>	<b>Longitude [°]</b>
Torre AC5312	8,5	-33,1492	-52,8939
Aerogerador 1	14,5	-33,1216	-52,9256
Aerogerador 2	11,5	-33,1261	-52,9214
Aerogerador 3	10,4	-33,1310	-52,9180
Aerogerador 4	10,0	-33,1380	-52,9120
Aerogerador 5	11,5	-33,1421	-52,9075
Aerogerador 6	9,9	-33,1446	-52,9014
Aerogerador 7	9,8	-33,1487	-52,8973
Aerogerador 8	8,5	-33,1519	-52,8925
Aerogerador 9	12,3	-33,1443	-52,9365
Aerogerador 10	11,0	-33,1484	-52,9320

Tabela A2 - Posição geográfica e altitude dos aerogeradores e torre de referência do parque eólico Ventos do Sertão.

<b>ID</b>	<b>Altitude [m]</b>	<b>Latitude [°]</b>	<b>Longitude [°]</b>
Torre AC7402	892,0	-10,5548	-40,5672
Aerogerador 1	905,6	-10,5394	-40,5624
Aerogerador 2	910,0	-10,5417	-40,5634
Aerogerador 3	910,0	-10,5435	-40,5651
Aerogerador 4	900,0	-10,5466	-40,5660
Aerogerador 5	898,1	-10,5485	-40,5678
Aerogerador 6	890,0	-10,5524	-40,5678
Aerogerador 7	879,7	-10,5559	-40,5692
Aerogerador 8	874,2	-10,5583	-40,5692
Aerogerador 9	870,4	-10,5608	-40,5694

Aerogerador 10	863,2	-10,5632	-40,5693
Aerogerador 11	855,3	-10,5656	-40,5701
Aerogerador 12	852,1	-10,5680	-40,5708
Aerogerador 13	849,1	-10,5703	-40,5714
Aerogerador 14	847,5	-10,5728	-40,5718
Aerogerador 15	844,0	-10,5752	-40,5718

## APÊNDICE B – Variáveis de entrada para os métodos com *machine learning*

Na Tabela B1 são listadas as variáveis selecionadas pela abordagem filtro com o coeficiente de correlação de Pearson em relação à velocidade do vento na posição da torre anemométrica de referência e altura do cubo para o parque eólico Ventos do Sertão (SER) e Aura Mirim II (MIR-2).

Na Tabela B2 são listadas as variáveis selecionadas pela mesma abordagem, porém em relação à geração do aerogerador equivalente médio. As variáveis nestas tabelas são: GUST – rajada de vento na superfície; MSLET – pressão atmosférica média ao nível do mar; UFLX – componente U do fluxo de momento superficial; VFLX - componente V do fluxo de momento superficial; USTM – componente U do movimento de tempestade (*storm motion*) de 6000-0 m acima do solo; CAPE – energia potencial convectiva disponível;  $v$  – velocidade do vento; UR - umidade relativa; SOILW – conteúdo volumétrico de umidade do solo; TCDC – camada de nuvem convectiva da cobertura total de nuvem; SPFH - umidade específica; T – temperatura; U – componente U da velocidade do vento; V – componente V da velocidade do vento; VRATE – taxa de ventilação da camada limite atmosférica; VVEL – velocidade vertical; HGT – altura geopotencial; PBLH – altura da camada limite atmosférica; MU – perturbação da massa de ar seco em coluna; UST -  $u_*$  da teoria de similaridade; omg – resultado da equação ômega; QVA-POR – taxa de mistura de vapor de água; th – temperatura potencial; eth – temperatura potencial equivalente; tv – temperatura virtual; P - pressão atmosférica; PB – pressão do estado base; EL\_PBL – escala de comprimento da camada limite atmosférica; TKE\_PBL – energia cinética turbulenta da camada limite atmosférica; QNCCN – número de concentração de núcleos de condensação de nuvens; twb – temperatura de bulbo úmido; P\_HYD – pressão hidrostática; SRH – helicidade relativa de tempestade (*storm relative helicity*); APTM – temperatura aparente; LFTX – índice levantado da superfície (*surface lifted index*); LHTFL – fluxo líquido de calor latente na superfície; TMIN – temperatura mínima 2 metros abaixo do chão;  $ULWRF_{sfc}$  – fluxo de radiação de ondas longas para cima na superfície; ACGRDFLX – fluxo de calor acumulado do solo; TSK – temperatura da superfície (*surface skin temperature*); TSLB – temperatura do solo.

Tabela B1 - Resultado do método de seleções de variáveis por coeficiente de Pearson para a velocidade do vento na torre anemométrica de referência e altura do cubo.

<b>Modelo</b>	<b>SER</b>	<b>MIR-2</b>
<b>GFS</b>	GUST; MSLET; UFLX; USTM; VFLX; SOILW; CAPE na superfície; $v$ em 10 e 80 m; UR em 1000 mb; SOILW entre 0 e 0,1 m de profundidade abaixo do chão; TCDC; SPFH 2 m abaixo do chão; T, U e V entre 30-0 mb acima do solo; U e V da camada limite atmosférica; U e V a 1829 m acima do nível médio do mar; VRATE; VVEL em 750, 800 e 850 mb; T em 100, 250, 300, 350, 850 e 900 mb; U em 750, 800, 850, 900, 925 e 975 mb; V em 800, 850 e 925 mb	HGT em 200 e 250 mb; T em 300 mb; PBLH; UFLX; VRATE; GUST; $v$ em 10 e 100 m
<b>GDPS</b>	HGT em 1015 mb; T em 250, 275, 300, 800 e 850; U em 750, 800, 850, 875, 900, 925 e 970 mb; U em 40 m; V em 800; 850, 875 e 900 mb; V em 120 m; $v$ em 800, 850, 875, 900, 925 e 970 mb; $v$ em 40 e 80 m	$v$ em 10 e 120 m; $v$ em 850, 875, 900, 925, 950, 970, 985, 1000 e 1015 mb
<b>WRF d01</b>	MU; UST; omg em 40 e 1000 m; QVA-POR em 1000 m; th em 2, 1000 e 10000 m; eth em 40, 1000, 10000 e 15000 m; tv em 500 e 1000 m; P em 2500 e 15000 m; PB em 500, 1000, 2500, 5000, 10000 e 12500 m; U em 10, 500 e 1000 m; V em 10, 50 e 1000 m; $v$ em 10, 48, 400 e 1000 m	PBLH; UST; SRH; EL_PBL em 40, 250 e 300 m; TKE_PBL em 40 m; QNCCN em 40 e 80 m; PB em 10000 e 12500 m; P em 12500 m; eth, twb e P_HYD em 10000 m; $v$ em 10, 160, 400, 500 e 1000 m
<b>WRF d02</b>	MU; omg em 40 m; th em 2, 1000 e 10000 m; eth em 40, 1000, 10000 e 15000 m; tv em 500 e 1000 m; P em 2500 e 15000 m; PB em 500, 1000, 2500, 5000, 10000 e 12500 m; U em 10, 500 e 1000 m; V em 50, 140 e 1000 m; $v$ em 10, 50, 76, 140, 250, 400 e 1000 m	PBLH; UST; SRH; EL_PBL em 40, 250 e 300 m; TKE_PBL em 40 m; QNCCN em 40 e 80 m; PB em 10000 e 12500 m; P em 12500 m; eth, twb e P_HYD em 10000 m; $v$ em 10, 160, 400, 500 e 1000 m

Tabela B2 - Resultado do método de seleções de variáveis por coeficiente de Pearson para o aerogerador equivalente médio.

<b>Modelo</b>	<b>SER</b>	<b>MIR-2</b>
<b>GFS</b>	APTM; GUST; LFTX; LHTFL; MSLET; th no nível sigma 0,995; TMIN; UFLX; $ULWRF_{sfC}$ ; USTM; VFLX; CAPE na superfície; CAPE de 180-0 mb e de 255-0 mb acima do solo; $v$ em 10 e 100 m; UR em 100 e 900 mb; UR de 30-0mb acima do solo; T em 100, 850 e 900 mb; T na superfície; T entre 30-0 mb acima do solo; U em 800, 850, 900, 925 e 975 mb; U e V da camada limite atmosférica; U e V de 30-0mb acima do solo; V em 850 e 925 mb; U e V a 1829 m acima do nível médio do mar; VVEL em 800 e 850 mb	UFLX; HPBL; VRATE; GUST; $v$ em 10 e 100 m
<b>GDPS</b>	HGT em 1015 mb; T em 800, 850, 875, 900, 925 e 985 mb; U e $v$ em 800, 850, 875, 900 e 970 mb; U em 40 e 120 m; V em 850, 875 e 900 mb; V em 120 m; $v$ em 40 e 80 m	T em 500 e 550 mb; $v$ em 10 e 120 m; $v$ em 850, 875, 900, 925, 950, 970, 985, 1000 e 1015 mb
<b>WRF d01</b>	ACGRDFLX; MU; TSK; TSLB; UST; th em 2 e 1000 m; omg em 40 e 1000 m; tv em 400 e 1000 m; P em 2500 e 15000 m; eth em 40 e 1000 m; UR em 300, 400 e 500 m; PB em 500, 1000, 2500, 5000 e 10000 m; U em 10, 500 e 1000 m; V em 10, 50 e 1000 m; $v$ em 10, 76 400 e 1000 m	PBLH; UST; SRH; EL_PBL em 40, 250 e 300 m; TKE_PBL em 40 m; QNCCN em 40 e 80 m; $v$ em 10, 250, 400, 500 e 1000 m
<b>WRF d02</b>	ACGRDFLX; MU; TSK; TSLB; th em 2 e 1000 m; tv em 500 e 1000 m; P em 2500 e 15000 m; eth em 40 e 1000 m; UR em 2, 300, 400 e 500 m; PB em 500, 1000, 2500, 5000 e 10000 m; U em 10, 500 e 1000 m; V em 76 e 1000 m; $v$ em 10, 50, 250, 400 e 1000 m	UST; SRH, EL_PBL em 56 m; TKE_PBL em 40 m; QNCCN em 40 e 80 m; $v$ em 10, 250, 400, 500 e 1000 m