

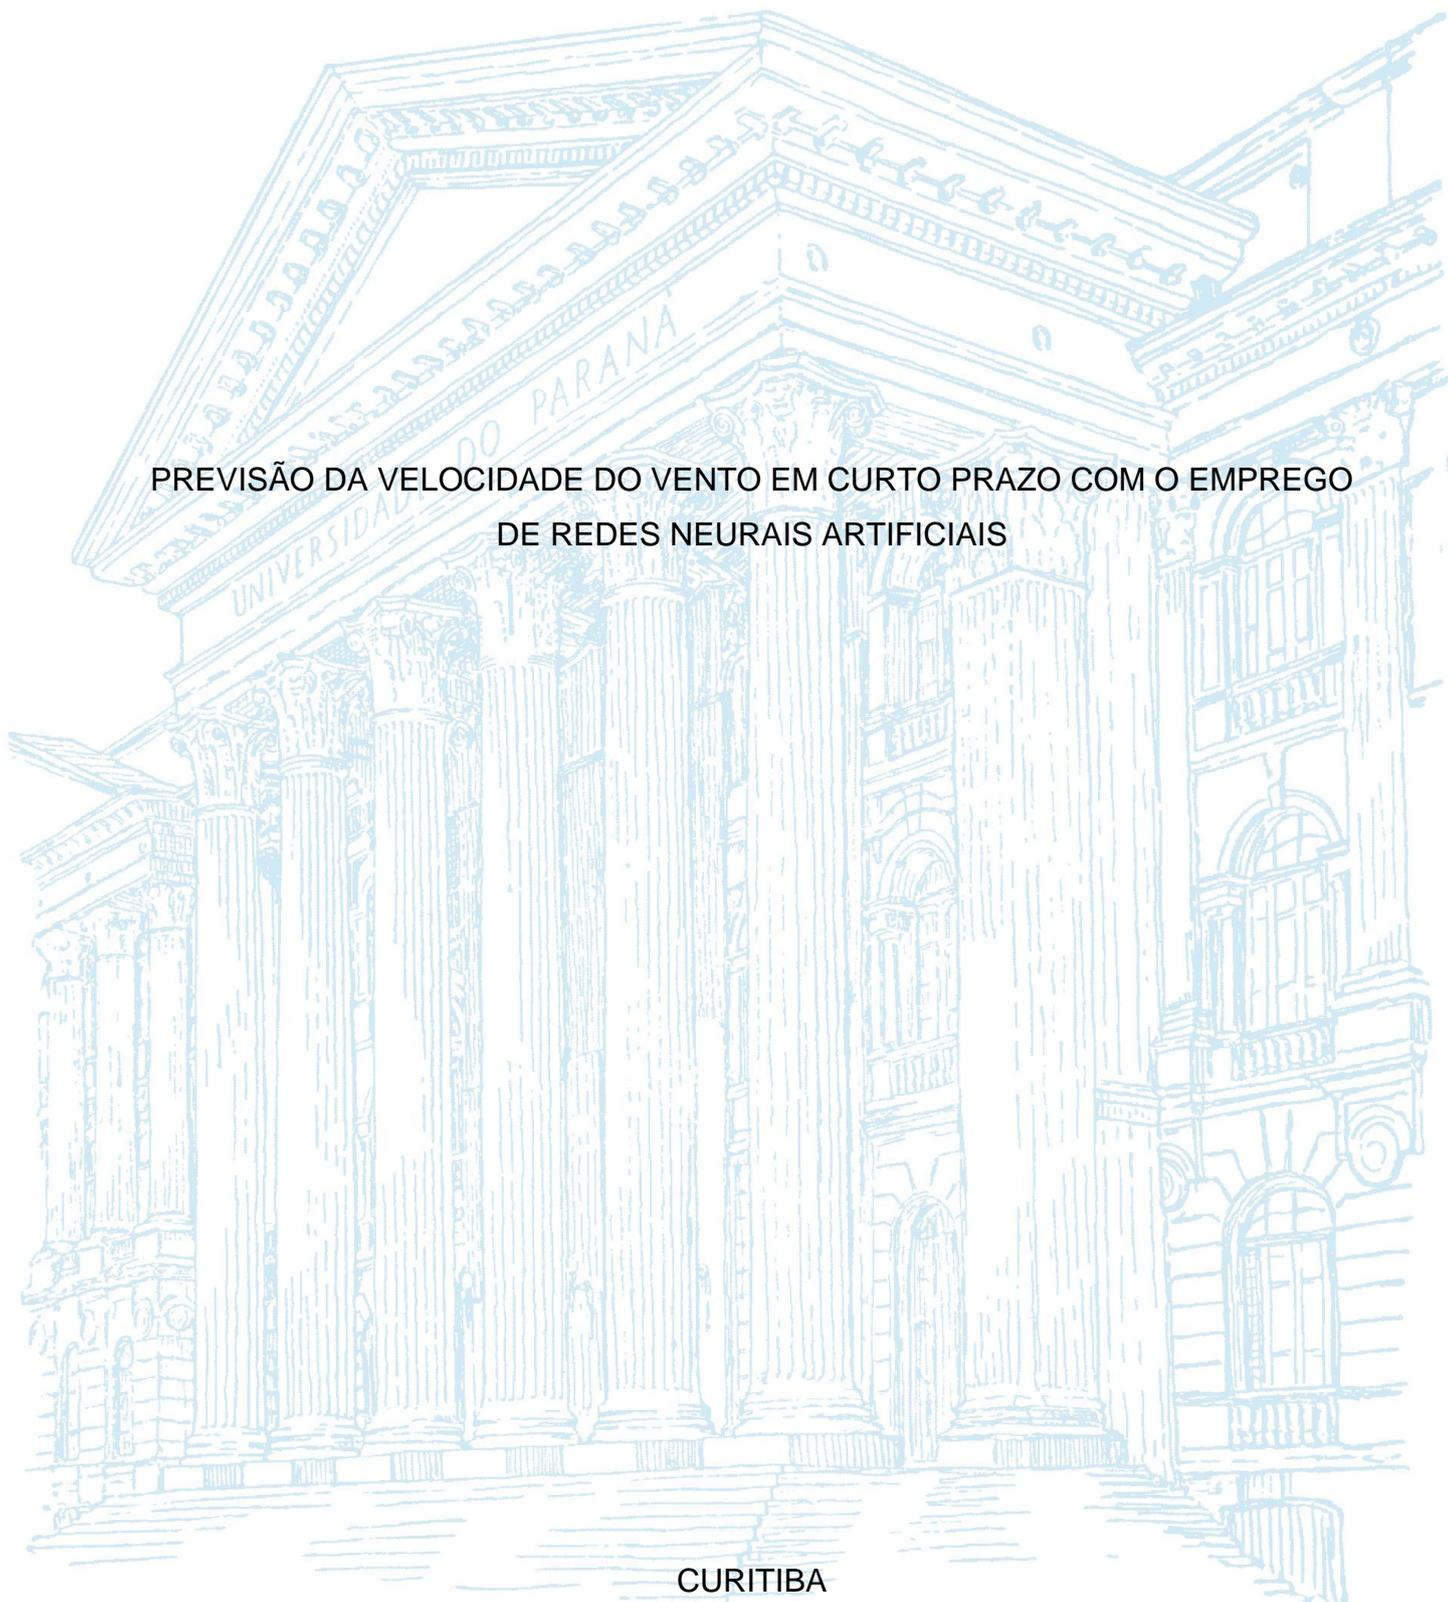
UNIVERSIDADE FEDERAL DO PARANÁ

RAFAELLA MOREIRA

PREVISÃO DA VELOCIDADE DO VENTO EM CURTO PRAZO COM O EMPREGO
DE REDES NEURAS ARTIFICIAIS

CURITIBA

2021



RAFAELLA MOREIRA

PREVISÃO DA VELOCIDADE DO VENTO EM CURTO PRAZO COM O EMPREGO
DE REDES NEURAS ARTIFICIAIS

Trabalho de Conclusão de Curso apresentado ao curso de Engenharia Ambiental, Setor de Tecnologia, Universidade Federal do Paraná, como requisito final para obtenção do título de Engenheira Ambiental.

Orientador: Prof. Dr. Ricardo Carvalho de Almeida.

CURITIBA

2021



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO PARANÁ
SETOR DE TECNOLOGIA
CURSO DE GRADUAÇÃO EM ENGENHARIA AMBIENTAL

TERMO DE APROVAÇÃO DE PROJETO FINAL

RAFAELLA MOREIRA

PREVISÃO DA VELOCIDADE DO VENTO EM CURTO PRAZO COM O EMPREGO DE REDES NEURAIS ARTIFICIAIS

Projeto Final de Curso, aprovado como requisito parcial para a obtenção do Diploma de Bacharel em Engenharia Ambiental no Curso de Graduação em Engenharia Ambiental do Setor de Tecnologia da Universidade Federal do Paraná, com nota 97,5 (noventa e sete e cinco décimos), pela seguinte banca examinadora:

Orientador(a):

Ricardo Carvalho de Almeida
Departamento de Engenharia Ambiental / UFPR

Membro(a) 1:

Gleiciane Fernanda de Carvalho Blanc
Lactec

Membro(a) 2:

Prof. Emilio G. F. Mercuri
Dpto. de Engenharia Ambiental
Universidade Federal do Paraná
Matrícula: 203974
Emilio Graciliano Ferreira Mercuri
Departamento de Engenharia Ambiental / UFPR

Curitiba, 03 de março de 2021

AGRADECIMENTOS

Agradeço à minha família pelo apoio prestado durante todo o período de faculdade, por toda a dedicação e amor e por todo o esforço que fizeram para que eu tivesse sempre a melhor educação possível.

Ao meu orientador, professor Dr. Ricardo Carvalho de Almeida por todo o incentivo, dedicação, confiança e amizade durante minha jornada, desde a iniciação científica até a conclusão deste trabalho. Sou muito grata por todo o auxílio dedicado a esse projeto e por todos os seus ensinamentos.

À Gleiciane Fernanda de Carvalho por aceitar o convite de compor a minha banca, por contribuir com melhorias para este trabalho e pela paciência e confiança durante meu período no Lactec.

Ao professor Emílio Mercuri por aceitar o convite de participar da minha banca e por toda a ajuda e conhecimentos transmitidos durante as disciplinas do curso.

Aos professores da UFPR, sobretudo aos do departamento de Engenharia Ambiental, que dedicaram tempo, esforços e paciência nas aulas. Deixo também meu agradecimento por tudo o que aprendi com vocês durante a graduação.

Aos meus amigos, em especial ao Andrei, Carol, Fabi e Bea, por me acompanharem durante todos esses anos, por compartilharem comigo momentos de alegria e deixarem os momentos de apreensão mais leves.

Aos meus amigos do Lactec, Antônio Hamerschmidt e Alcides Conte Neto, por toda a ajuda em programação.

Meu muito obrigada a todos que não foram mencionados, mas que contribuíram de alguma forma na minha trajetória acadêmica.

RESUMO

O objetivo deste trabalho é avaliar o resultado da previsão da velocidade do vento para os horizontes de 1, 3, 6, 12, 18 e 24 horas à frente com o uso de uma rede neural artificial de função de base radial (RBF). O conjunto de dados que foram utilizados são provenientes da estação anemométrica de Petrolina (PE), do projeto SONDA, o qual coleta dados nas alturas de 25 e 50 metros. A seleção das variáveis ótimas de entrada no modelo é uma das principais etapas e, para isso, foi aplicado o método de regressão *stepwise*, passo *forward*, com o uso da rede neural para obter a função não linear para cada horizonte de tempo. Essa etapa atingiu um tempo de processamento máximo de 29 horas. Visando um melhor desempenho da rede neural foi considerado, para cada um dos horizontes de previsão, uma diferente configuração da RNA RBF, a qual variou nos números de neurônios da camada de entrada e nos da camada oculta. Os resultados mostraram que a rede neural RBF teve um bom desempenho, alcançando para o horizonte de previsão de 1 hora um REQM de 0,919 m/s na altura de 25 metros e de 1,083 m/s na altura de 50 metros. Verificou-se que esse erro aumentava conforme o horizonte de previsão e, ao fim do período do dia, esse erro diminuía novamente, em função do ciclo diário da camada limite. Assim, para o horizonte de previsão de 24 horas, os REQM resultantes foram de 0,990 m/s e de 1,155 m/s, para 25 e 50 metros de altura, respectivamente. Ademais, verificou-se que os erros de previsão aumentaram conforme a altura de medição.

Palavras-chave: Rede neural artificial. Rede neural RBF. Energia eólica. Previsão da velocidade do vento. Previsão em curto prazo.

ABSTRACT

The aim of this study is to evaluate the result of the wind speed forecast for the horizons of 1, 3, 6, 12, 18 and 24 hours ahead applying an artificial neural network of radial base function (RBF). The data set that was used comes from the anemometric station of Petrolina (PE), of the SONDA project, which collects data at the heights of 25 and 50 meters. The selection of the optimal input variables in the model is an important step and, for this, the stepwise regression method, forward step, was applied, using the neural network to obtain the non-linear function for each horizon of time. This step has reached a maximum processing time of 29 hours. Aiming at a better performance of the neural network, a different configuration of RNA RBF was considered for each of the forecast horizons, which varied in the numbers of neurons of the input layer and of the hidden layer. The results showed that the RBF neural network performed well, reaching a REQM of 0.919 m/s at a height of 25 meters and 1.083 m/s at a height of 50 meters for the 1-hour forecast horizon. It was verified that this error increased as the forecast horizon increased, and at the end of the period of a day, this error decreased again, due to the daily cycle of the boundary layer. Thus, for the 24-hour forecast horizon, the resulting REQM were 0.990 m/s and 1.155 m/s for 25 and 50 meters high, respectively. Furthermore, it was verified that the forecast errors increased according to the measurement height.

Key-words: Artificial neural network. RBF neural network. Wind power. Wind speed forecast. Short-term forecast.

LISTA DE FIGURAS

FIGURA 1 – COMPARAÇÃO DA MATRIZ ELÉTRICA MUNDIAL DE 2015 (a) E 2016 (b), RESPECTIVAMENTE.	18
FIGURA 2 – COMPARAÇÃO DAS MATRIZES ELÉTRICAS DO BRASIL DE 2017 (a) E 2018 (b).	19
FIGURA 3 – GERAÇÃO EÓLICA AO LONGO DOS ANOS NO BRASIL.	20
FIGURA 4 – CAPACIDADE INSTALADA (POTÊNCIA) DO CONJUNTO DE USINAS EÓLICAS NO MUNDO AO LONGO DOS ANOS.	22
FIGURA 5 – CAPACIDADE INSTALADA (POTÊNCIA) DO CONJUNTO DE USINAS EÓLICAS NO BRASIL AO LONGO DOS ANOS.	23
FIGURA 6 – REPRESENTAÇÃO DA CURVA DE POTÊNCIA DE UMA TURBINA EÓLICA.	24
FIGURA 7 – PERFIL DA VELOCIDADE DO VENTO.	26
FIGURA 8 – REPRESENTAÇÃO DE UM NEURÔNIO BIOLÓGICO.	27
FIGURA 9 – ESQUEMA REPRESENTATIVO DO NEURÔNIO ARTIFICIAL.	28
FIGURA 10 – REPRESENTAÇÃO GRÁFICA DA FUNÇÃO DE ATIVAÇÃO LINEAR.	30
FIGURA 11 – REPRESENTAÇÃO GRÁFICA DA FUNÇÃO DE ATIVAÇÃO DEGRAU.	30
FIGURA 12 – REPRESENTAÇÃO GRÁFICA DA FUNÇÃO DE ATIVAÇÃO GAUSSIANA.	31
FIGURA 13 – REPRESENTAÇÃO GRÁFICA DA FUNÇÃO DE ATIVAÇÃO SIGMÓIDE LOGÍSTICA.	32
FIGURA 14 – ESQUEMA REPRESENTATIVO DA ESTRUTURA DE UMA REDE NEURAL RBF.	34
FIGURA 15 – REPRESENTAÇÃO DE UMA FUNÇÃO DE ERROS CONTENDO MÍNIMOS LOCAIS E GLOBAL.	36
FIGURA 16 – MAPA DE LOCALIZAÇÃO DA ESTAÇÃO ANEMOMÉTRICA DO PROJETO SONDA.	39
FIGURA 17 – FOTO DA TORRE ANEMOMÉTRICA DE PETROLINA.	40
FIGURA 18 – REPRESENTAÇÃO DA POSIÇÃO MÉDIA DA ZCIT NO a) VERÃO b) INVERNO.	41

FIGURA 19 – VALORES MENSAIS DA VELOCIDADE DO VENTO A 25 METROS.	42
FIGURA 20 – VALORES MENSAIS DA VELOCIDADE DO VENTO A 50 METROS.	43
FIGURA 21 – CICLO DIÁRIO DA VELOCIDADE DO VENTO A 25 METROS.	44
FIGURA 22 – CICLO DIÁRIO DA VELOCIDADE DO VENTO A 50 METROS.	45
FIGURA 23 – ESQUEMA REPRESENTATIVO DAS ETAPAS DA VALIDAÇÃO DOS DADOS MEDIDOS.	47
FIGURA 24 – EXEMPLO DE UM CICLO REALIZADO PELO MÉTODO DE REGRESSÃO <i>STEPWISE</i> PARA A VELOCIDADE DO VENTO A 25 METROS.	61
FIGURA 25 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 1 HORA À FRENTE DA VELOCIDADE DO VENTO A 25 METROS.	62
FIGURA 26 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 3 HORAS À FRENTE DA VELOCIDADE DO VENTO A 25 METROS.	62
FIGURA 27 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 6 HORAS À FRENTE DA VELOCIDADE DO VENTO A 25 METROS.	63
FIGURA 28 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 12 HORAS À FRENTE DA VELOCIDADE DO VENTO A 25 METROS.	64
FIGURA 29 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 18 HORAS À FRENTE DA VELOCIDADE DO VENTO A 25 METROS.	64
FIGURA 30 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 24 HORAS À FRENTE DA VELOCIDADE DO VENTO A 25 METROS.	65
FIGURA 31 – EXEMPLO DE UM CICLO REALIZADO PELO MÉTODO DE REGRESSÃO <i>STEPWISE</i> PARA A VELOCIDADE DO VENTO A 50 METROS.	66

FIGURA 32 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 1 HORA À FRENTE DA VELOCIDADE DO VENTO A 50 METROS.	67
FIGURA 33 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 3 HORAS À FRENTE DA VELOCIDADE DO VENTO A 50 METROS.	67
FIGURA 34 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 6 HORAS À FRENTE DA VELOCIDADE DO VENTO A 50 METROS.	68
FIGURA 35 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 12 HORAS À FRENTE DA VELOCIDADE DO VENTO A 50 METROS.	69
FIGURA 36 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 18 HORAS À FRENTE DA VELOCIDADE DO VENTO A 50 METROS.	69
FIGURA 37 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 24 HORAS À FRENTE DA VELOCIDADE DO VENTO A 50 METROS.	70
FIGURA 38 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 1 HORA ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.	71
FIGURA 39 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 3 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.	72
FIGURA 40 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 6 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.	72
FIGURA 41 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 12 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.	73

FIGURA 42 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 18 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.	73
FIGURA 43 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 24 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.	74
FIGURA 44 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 1 HORA ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.	75
FIGURA 45 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 3 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.	75
FIGURA 46 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 6 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.	76
FIGURA 47 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 12 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.	76
FIGURA 48 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 18 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.	77
FIGURA 49 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 24 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.	77

LISTA DE TABELAS

TABELA 1 – RELAÇÃO DO TEMPO DE PREVISÃO PARA CADA HORIZONTE DE PREVISÃO.	37
TABELA 2 – RELAÇÃO DOS CÓDIGOS DAS VARIÁVEIS SELECIONADAS APÓS AS ETAPAS DE VALIDAÇÃO.	49
TABELA 3 – VARIÁVEIS SELECIONADAS COMO PREDITORAS APÓS A ETAPA DE VALIDAÇÃO DOS DADOS.	55
TABELA 4 – CORRELAÇÕES CRUZADAS ENTRE A VELOCIDADE DO VENTO A 25 METROS E OS POSSÍVEIS PREDITORES, COM ATRASO DE ATÉ 30 HORAS.	57
TABELA 5 – CORRELAÇÕES CRUZADAS ENTRE A VELOCIDADE DO VENTO A 50 METROS E OS POSSÍVEIS PREDITORES, COM ATRASO DE ATÉ 30 HORAS.	58
TABELA 6 – CONFIGURAÇÃO DO NÚMERO DE NEURÔNIOS DE CADA HORIZONTE DE PREVISÃO NA RNA RBF PARA A PREVISÃO DA VELOCIDADE DO VENTO A 25 METROS.	70
TABELA 7 – CONFIGURAÇÃO DO NÚMERO DE NEURÔNIOS DE CADA HORIZONTE DE PREVISÃO NA RNA RBF PARA A PREVISÃO DA VELOCIDADE DO VENTO A 50 METROS.	71
TABELA 8 – DESEMPENHO DA RNA RBF NA PREVISÃO DA VELOCIDADE DO VENTO A 25 METROS.	74
TABELA 9 – DESEMPENHO DA RNA RBF NA PREVISÃO DA VELOCIDADE DO VENTO A 50 METROS.	78

LISTA DE ABREVIATURAS OU SIGLAS

a.C	- Antes de Cristo
ADALINE	- <i>Adaptive Linear Element</i>
ARIMA	- Auto-Regressivo Integrado de Médias Móveis
BEN	- Balanço Energético Nacional
CLA	- Camada Limite Atmosférica
CLS	- Camada Limite Superficial
Correl	- Correlação de Pearson
Dr	- Doutor
EMA	- Erro Médio Absoluto
EPE	- Empresa de Pesquisa Energética
EPM	- Erro Percentual Médio
EUA	- Estados Unidos da América
GW	- Gigawatt
GWh	- Gigawatt-hora
INPE	- Instituto Nacional de Pesquisas Espaciais
IRENA	- <i>Internacional Renewable Energy Agency</i>
kW	- Quilowatt
m/s	- Metros por Segundo
MME	- Ministério de Minas e Energia
MLP	- Perceptron de Múltiplas Camadas
MW	- Megawatt
NARX	- Rede Não Linear Autorregressiva com Entradas Exógenas
O	- Oeste
ONS	- Operador Nacional do Sistema
PE	- Pernambuco
Press	- Pressão Atmosférica
Rad	- Radiação
RBF	- Função de Base Radial
REQM	- Raiz do Erro Quadrático Médio
RNA	- Rede Neural Artificial
S	- Sul
SONDA	- Sistema de Organização Nacional de Dados Ambientais

Tp25	- Temperatura a 25 metros
Tp50	- Temperatura a 50 metros
Tps	- Temperatura na superfície
TWh	- Terawatt-hora
U10	- Componente zonal da direção do vento a 10 metros
U25	- Componente zonal da direção do vento a 25 metros
U50	- Componente zonal da direção do vento a 50 metros
UR	- Umidade relativa
USA	- <i>United States of America</i>
V10	- Componente meridional da direção do vento a 10 metros
V25	- Componente meridional da direção do vento a 25 metros
V50	- Componente meridional da direção do vento a 50 metros
W10	- Velocidade do vento em 10 metros
W25	- Velocidade do vento em 25 metros
W50	- Velocidade do vento em 50 metros
WRF	- <i>Weather Research and Forecasting</i>
ZCIT	- Zona de Convergência Intertropical

SUMÁRIO

1	INTRODUÇÃO	15
1.1	JUSTIFICATIVA	16
1.2	OBJETIVOS	17
1.2.1	Objetivo geral	17
1.2.2	Objetivos específicos.....	17
1.3	ESTRUTURA DO TRABALHO.....	17
2	REVISÃO BIBLIOGRÁFICA.....	18
2.1	ENERGIA ELÉTRICA.....	18
2.1.1	Energia eólica.....	20
2.1.1.1	História	20
2.1.1.2	Aproveitamento da Energia Eólica	23
2.2	REDES NEURAIS ARTIFICIAIS	27
2.2.1	Neurônio Biológico	27
2.2.2	Neurônios Artificiais.....	28
2.2.3	Função de Ativação.....	29
2.2.4	Método <i>Screening Regression</i>	32
2.2.5	Arquitetura e treinamento de uma rede neural artificial.....	33
2.2.6	A RNA de Função de Base Radial	34
2.2.6.1	Treinamento da rede neural artificial RBF	35
2.3	ESTUDOS REALIZADOS SOBRE A PREVISÃO DA VELOCIDADE DO VENTO.....	37
3	MATERIAIS E MÉTODOS	39
3.1	ÁREA DE ESTUDO.....	39
3.2	BASE DE DADOS METEOROLÓGICAS	45
3.3	METODOLOGIA.....	49
3.3.1	Análise dos dados	49
3.3.2	Seleção de preditores.....	49
3.3.3	Treinamento da rede neural	51
3.3.4	Análise estatística dos resultados	52
4	APRESENTAÇÃO DE RESULTADOS.....	55
4.1	ANÁLISE DOS DADOS.....	55
4.2	CORRELAÇÕES	55

4.3	SELEÇÃO DOS PREDITORES ÓTIMOS	59
4.3.1	Seleção de variáveis de entrada para a previsão da velocidade do vento a 25 metros	60
4.3.1.1	Horizonte de previsão de 1 hora.....	61
4.3.1.2	Horizonte de previsão de 3 horas.....	62
4.3.1.3	Horizonte de previsão de 6 horas.....	63
4.3.1.4	Horizonte de previsão de 12 horas.....	63
4.3.1.5	Horizonte de previsão de 18 horas.....	64
4.3.1.6	Horizonte de previsão de 24 horas.....	65
4.3.2	Seleção de variáveis de entrada para a previsão da velocidade do vento a 50 metros	65
4.3.2.1	Horizonte de previsão de 1 hora.....	66
4.3.2.2	Horizonte de previsão de 3 horas.....	67
4.3.2.3	Horizonte de previsão de 6 horas.....	68
4.3.2.4	Horizonte de previsão de 12 horas.....	68
4.3.2.5	Horizonte de previsão de 18 horas.....	69
4.3.2.6	Horizonte de previsão de 24 horas.....	70
4.4	VERIFICAÇÃO DO DESEMPENHO DA REDE NEURAL RBF	70
4.4.1	Previsão da velocidade do vento a 25 metros.....	71
4.4.2	Previsão da velocidade do vento a 50 metros.....	74
4.5	DISCUSSÃO DOS RESULTADOS	78
5	CONCLUSÕES E RECOMENDAÇÕES	80
	REFERÊNCIAS.....	81
	APÊNDICE 1 — RESULTADOS DO MÉTODO DE REGRESSÃO	87

1 INTRODUÇÃO

O avanço tecnológico, a qualidade de vida da sociedade e o desenvolvimento industrial estão intimamente relacionados com a energia elétrica, em que as diferentes fontes existentes para a geração desta estão sendo muito discutidas ao longo dos últimos anos (ANDRADE, 2004).

Existem diversas formas de energia, as quais podem ser agrupadas no grupo de renováveis ou não renováveis. O primeiro é proveniente de fontes naturais reabastecidas continuamente em uma escala de tempo curta (escala de tempo humana), como a hidráulica, eólica e solar, as quais atuam a partir da força da água, dos ventos e da radiação solar, respectivamente. Já no segundo agrupamento estão aquelas que têm recursos limitados e que podem vir a esgotar ao longo do tempo. A exemplo destas destacam-se as energias derivadas do petróleo e do carvão (CCEE, 2019; ENEL GREEN POWER, 2020).

Grande parte do consumo mundial é decorrente das fontes não renováveis de energia elétrica, ou fontes convencionais, as quais possuem alto rendimento (pouca quantidade de óleo produz bastante energia, por exemplo) e facilidade de transporte e de armazenamento, além de serem fontes não variáveis de energia, já que não dependem das condições meteorológicas locais (EPE, 2020b). Cada vez mais as fontes renováveis estão conquistando espaço nas matrizes elétricas dos países. De acordo com dados do relatório da *Internacional Renewable Energy Agency* (IRENA), a capacidade de energia renovável aumentou cerca de 175000 MW de 2018 para 2019 (IRENA, 2020a).

Uma das energias com maior destaque é a eólica, a qual está em expansão no Brasil. De 2017 para 2018 a geração elétrica por essa fonte aumentou em 14,4% (EPE, 2019a) e de 2018 para 2019 15,5% (EPE, 2020a). Em meados de 2020 o país já possuía pelo menos 601 usinas instaladas, as quais atingiram capacidade de 16 GW (ABEEólica, 2020; IRENA, 2020a).

Por haver uma dependência em relação às condições meteorológicas, o estudo e a estimativa da velocidade do vento são essenciais para que possa ser avaliado o aproveitamento efetivo do recurso eólico na região de interesse. Ademais, a previsão de curto prazo (1 a 72 horas) é importante para a operação do sistema elétrico, sendo útil para o planejamento energético, de forma a auxiliar no balanceamento da geração elétrica, isto é, na determinação da necessidade de

energia reserva (CCEE, 2020). Esse planejamento está relacionado com a quantidade de energia que é necessária agendar para suprir a demanda requerida por todos os consumidores.

Deste modo, o aperfeiçoamento de ferramentas de previsão é fundamental para que haja segurança energética nacional (FERREIRA, 2012; COIMBRA et al., 2018).

A utilização de inteligência artificial, especialmente as redes neurais artificiais, tem se tornado importante para a simulação de variáveis ambientais (RODRIGUES, 2007). O método de redes neurais artificiais é eficiente para as previsões de curto prazo, além de ser uma opção cada vez mais consolidada (VERAS, 2013 apud COSTA, 2016).

Com base no cenário da energia elétrica e na importância de uma maior participação da energia elétrica gerada por fonte eólica na matriz nacional, neste trabalho será avaliada a possibilidade de realizar a previsão da velocidade do vento em um horizonte de curto prazo para as alturas de 25 e 50 metros, com o emprego da rede neural artificial RBF. A base de dados utilizada será de uma estação anemométrica em Petrolina (PE), do projeto SONDA (Sistema de Organização Nacional de Dados Ambientais), criado pelo INPE (Instituto Nacional de Pesquisas Espaciais).

1.1 JUSTIFICATIVA

A escolha deste tema foi motivada pelo fato de a geração por fonte eólica ter cada vez mais importância na matriz elétrica brasileira e por depender diretamente da disponibilidade de vento na região para a produção de energia elétrica. Deste modo, uma das alternativas para que esta fonte ganhe uma maior confiabilidade é a otimização das previsões da velocidade do vento em um horizonte de curto prazo, pois com resultados mais acurados essas previsões podem auxiliar no melhoramento do planejamento energético.

1.2 OBJETIVOS

1.2.1 Objetivo geral

O objetivo geral deste trabalho é analisar o desempenho da previsão da velocidade do vento para a geração eólica na localidade de Petrolina (PE), em horizontes de curto prazo utilizando a rede neural artificial RBF (*Radial Basis Function*), para as alturas de 25 e 50 metros em relação ao nível do solo.

1.2.2 Objetivos específicos

Como objetivos específicos destacam-se:

- Seleção dos dados de entrada da rede neural a partir dos critérios de controle de qualidade fornecido pelo projeto SONDA;
- A seleção dos preditores ótimos da camada de entrada do modelo;
- A determinação do número ótimo de neurônios da camada oculta;
- A comparação entre os resultados de desempenho da rede dos 6 horizontes de previsão selecionados (1, 3, 6, 12, 18 e 24 horas).

1.3 ESTRUTURA DO TRABALHO

Este documento está dividido em cinco partes. Na seção 1 foi apresentada uma introdução sobre o assunto e os objetivos geral e específicos. Na seção 2, tem-se a revisão bibliográfica, a qual abrange os temas de energia, de redes neurais artificiais e estudos referentes ao tema aqui tratado. Na seção 3, descreve-se a área de estudo, os dados de referência, a metodologia a ser utilizada para a realização deste trabalho e as métricas de validação utilizadas. Na seção 4, são mostrados os resultados que foram obtidos, seguidos da sua discussão. Tem-se, na seção 5, as conclusões gerais e recomendações para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

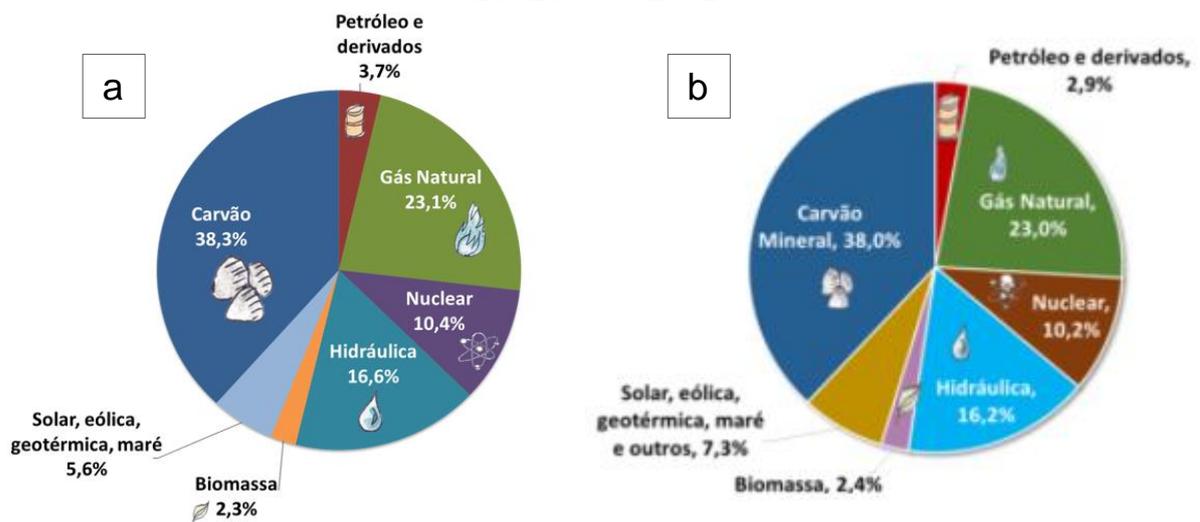
2.1 ENERGIA ELÉTRICA

A energia elétrica se faz necessária em diversas tarefas cotidianas e para o bom funcionamento de serviços, indústrias, comércio, lazer e atividades domésticas (BRANDÃO, 2014; LAMARÃO, 1997; FERREIRA, 2012). Além disso, é importante para a cidadania e inclusão social (CPFL, 2019), sendo indispensável à sociedade.

O balanço energético de um país é feito de acordo com os dados de geração e consumo final das fontes de energias ofertadas, podendo estas ser convencionais ou incentivadas. Esse balanço determina a matriz energética e elétrica do país. A matriz energética é a demanda total de energia. Já a matriz elétrica são as fontes disponíveis apenas para a geração de energia elétrica (EPE, 2020c; MME, 2017).

A seguir são mostradas as matrizes elétricas mundial (FIGURA 1) e do Brasil (FIGURA 2), com comparações ao longo dos anos.

FIGURA 1 – COMPARAÇÃO DA MATRIZ ELÉTRICA MUNDIAL DE (a) 2017 E (b) 2018. RESPECTIVAMENTE.



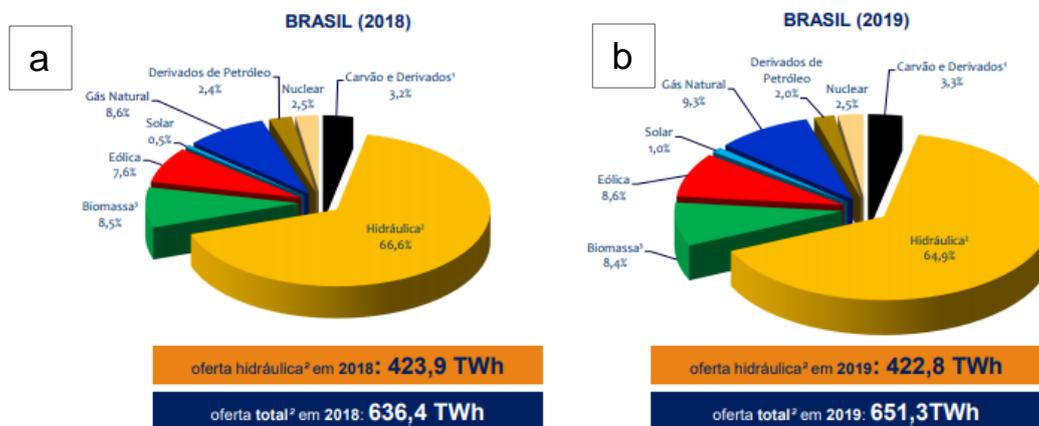
FONTE: a) EPE, 2019b; b) EPE, 2020c.

Na FIGURA 1-a é apresentada a matriz elétrica mundial por fonte no ano de 2017 e na FIGURA 1-b no ano de 2018. Observa-se que o percentual referente às fontes convencionais e não-renováveis reduziu, enquanto o percentual das fontes solar, eólica, geotérmica, maré e biomassa aumentou. Infe-re-se, então, que as fontes

incentivadas estão em crescente participação na matriz elétrica mundial, em detrimento das fontes convencionais e não renováveis.

Para dados brasileiros, a EPE (Empresa de Pesquisa Energética) é a responsável pela formulação e publicação do Balanço Energético Nacional (BEN). A versão mais atualizada é o BEN2020, o qual tem como base os dados de 2019. Na FIGURA 2 abaixo há uma comparação entre as matrizes elétricas brasileiras de 2018 e de 2019. Vê-se que a matriz nacional é predominantemente composta por fontes renováveis de energia, com destaque para as hidrelétricas (64,9% em 2019).

FIGURA 2 – COMPARAÇÃO DAS MATRIZES ELÉTRICAS DO BRASIL DE (a) 2018 E (b) 2019.

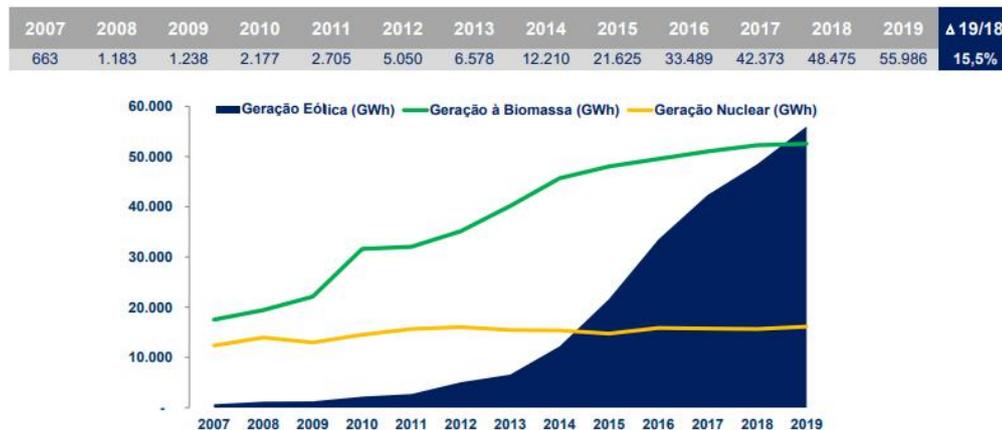


FONTE: EPE, 2020a.

De 2018 para 2019 a energia eólica no Brasil teve crescimento de 15,5% e a solar de 204,7%. Apesar do crescimento da fonte proveniente da radiação solar ser grande, essa energia ainda não é tão representativa na matriz elétrica, quando comparada com as outras fontes de energia. Em 2019, a geração eólica foi de 55.986 GWh (EPE, 2020a).

Na FIGURA 3 abaixo tem-se a evolução da geração eólica ao longo dos anos em comparação com as gerações à biomassa e nuclear. Nota-se que, principalmente nos últimos anos, essa fonte tem progredido bastante para a contribuição de geração de energia.

FIGURA 3 – GERAÇÃO EÓLICA AO LONGO DOS ANOS NO BRASIL.



FONTE: EPE, 2020a.

Nota-se na FIGURA 3 que em questão de 5 anos a geração eólica superou a geração nuclear e, recentemente, ultrapassou a geração de eletricidade à biomassa (EPE, 2020a).

A partir da análise feita anteriormente observa-se que a tendência é a inserção cada vez maior de fontes renováveis para a geração de energia.

2.1.1 Energia eólica

A energia eólica é a energia cinética contida nas massas de ar em movimento, isto é, no vento (CCEE, 2019; ANEEL, 2005).

Foi visto no item 2.1 que essa energia está em expansão tanto no Brasil quanto no resto do mundo. Desta forma, neste subitem será abordada especificamente essa fonte energética, relatando brevemente seu histórico, como ocorre a formação dos ventos e os princípios físicos mais importantes.

2.1.1.1 História

A energia a partir dos ventos é utilizada há milhares de anos para, principalmente, o transporte por embarcações marítimas (GAVINO, 2011). De acordo com Silva (2004), em 1000 a.C., os fenícios, possuíam barcos movidos unicamente a vela, que eram utilizados para a navegação comercial.

Outra descoberta, ao longo dos séculos, foi o moinho de vento. Os primeiros registros destes datam do século VII, ano 644, na Pérsia (localização atual do Irã),

onde possuíam vantagens em relação aos movidos pela água, pois os persas tinham maior disponibilidade dos ventos em relação aos cursos de água, que nem sempre ficavam próximos de onde eram necessários (CHESF-BRASCEP, 1987 & SHEPHERD, 1994 APUD CRESESB, 2017). Durante muito tempo foi usado para processos como moagem de grãos, bombeamento de água e para movimentar serrarias. Porém, seu uso teve um decréscimo devido à revolução industrial, a qual introduziu as máquinas a vapor.

O primeiro moinho de vento utilizado para a produção de energia elétrica foi construído na Escócia, em 1887, pelo professor James Blyth, numa torre de 10 metros de altura. Contudo, o invento não evoluiu, por não ter viabilidade econômica (MME, 2016).

Em 1888 Charles Brush (1849-1929) desenvolveu uma turbina eólica para produção de energia elétrica. O modelo possuía 144 pás, com 17 metros de diâmetro, em uma torre de 18 metros e com potência de 12 kW (DALMAZ, 2007). Durante a operação da turbina eólica de Brush, Poul la Cour, da Dinamarca, descobriu que para a geração de energia elétrica é mais adequada a utilização de uma turbina eólica com menor número de pás e maior velocidade de rotação. Ele foi, então, considerado o pioneiro no desenvolvimento dos modernos aerogeradores (CRESESB, 2017).

Por volta de 1930, nos EUA, passou-se a usar a energia eólica para produzir energia elétrica com pequenos aerogeradores ligados a baterias, que possibilitaram o acesso a eletricidade de habitantes afastados dos centros urbanos (GAVINO, 2011).

Com a eletricidade distribuída através de cabos até as áreas mais afastadas, a geração eólica isolada foi perdendo sua utilidade com o passar dos anos (AMARANTE et al., 2001). Em 1941 ocorreu a primeira experiência acima de 1 MW, conectado à rede de Vermont – USA, em que 1.000 residências foram atendidas. Neste experimento foi usada uma turbina de 1,25 MW movida por um sistema de duas pás (MME, 2016).

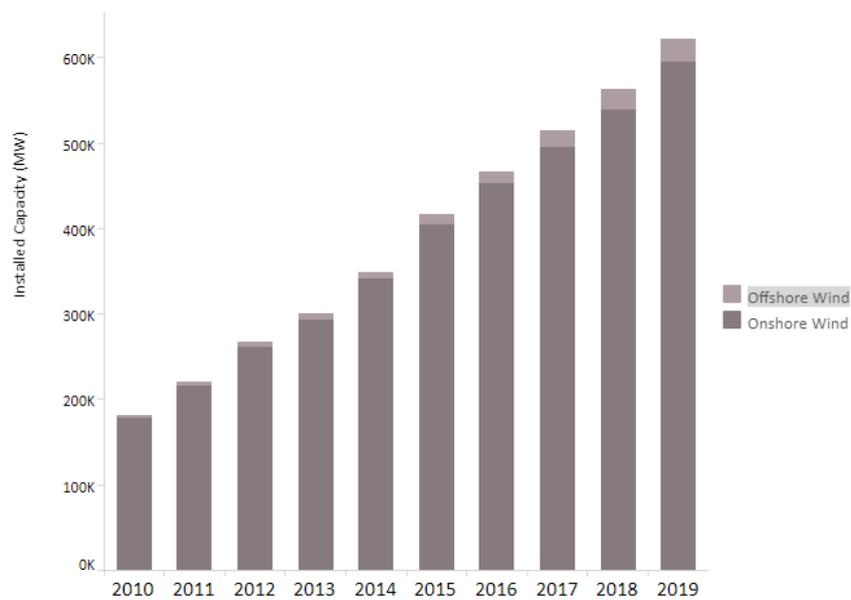
Com a crise do petróleo, nas décadas de 1970 e 1980, diversos países (principalmente EUA e os da Europa) começaram a estudar outras formas para gerar energia e, então, a eólica teve maior inclusão (AMARANTE et al., 2001 apud DALMAZ, 2007).

Assim, com os incentivos ao emprego da energia dos ventos, principalmente na Dinamarca e Alemanha, ocorreram grandes desenvolvimentos tecnológicos na

fabricação dos aerogeradores, o que permitiu uma redução nos custos e melhoramento do rendimento das máquinas (DALMAZ, 2007).

No final de 2010, a potência mundial instalada de origem eólica era de, aproximadamente, 200 GW e ao final de 2019 o valor da potência instalada superou 600 GW, conforme visualiza-se na FIGURA 4 (IRENA, 2020b).

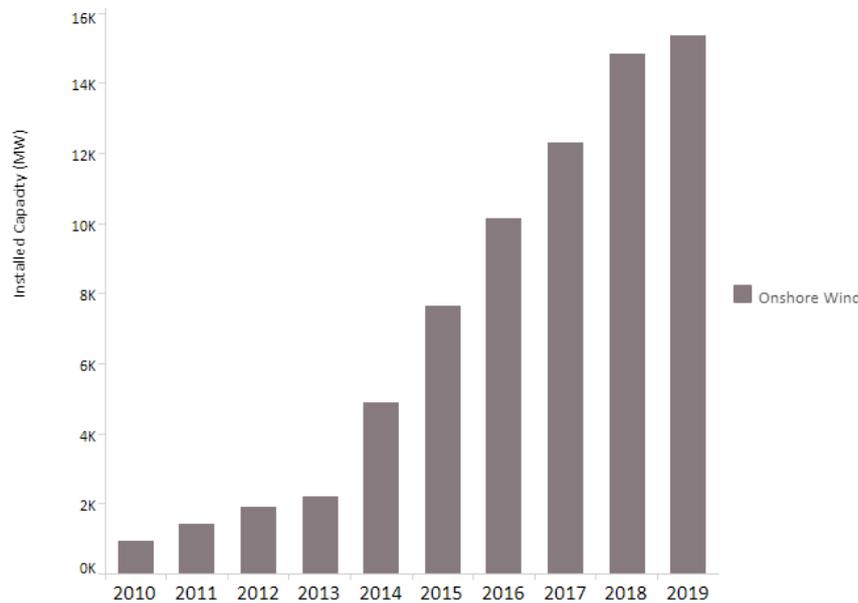
FIGURA 4 – CAPACIDADE INSTALADA (POTÊNCIA) DO CONJUNTO DE USINAS EÓLICAS NO MUNDO AO LONGO DOS ANOS.



FONTE: IRENA, 2020b.

Observando, agora, o cenário brasileiro de energia eólica (FIGURA 5), vê-se que a capacidade instalada em 2010 era de apenas 1 GW, enquanto ao fim de 2019 atingiu cerca de 15,3 GW.

FIGURA 5 – CAPACIDADE INSTALADA (POTÊNCIA) DO CONJUNTO DE USINAS EÓLICAS NO BRASIL AO LONGO DOS ANOS.



De acordo com a ABEEólica (2020), foi atingida, em junho de 2020, a capacidade instalada de 16 GW. Por fim, foi prevista uma capacidade de pelo menos 24 GW até o ano de 2024 (ABEEólica, 2020).

Pelos dados apresentados acima, das potências mundial e nacional, é possível verificar que a geração vem aumentando rapidamente ao longo dos últimos anos.

2.1.1.2 Aproveitamento da Energia Eólica

O regime dos ventos em um local específico deve ser estudado para que o aproveitamento da energia eólica seja o máximo possível. Para isso, deve-se considerar a direção do vento, a curva de potência e o perfil vertical da velocidade, conforme mostrado a seguir.

2.1.1.2.1 Direção do vento

A direção predominante do vento é importante para que os aerogeradores sejam dispostos em locais apropriados para a máxima geração de energia. É possível observar essa propriedade em rosas dos ventos. Deste modo, as pás do aerogerador devem ficar direcionadas em 90° (perpendiculares) à direção dos ventos. Além disso,

as esteiras dos aerogeradores devem ser dispostas adequadamente, a fim de evitar a produção de interferência entre estes no recebimento do vento.

2.1.1.2.2 Potência

A potência disponível no vento pode ser expressa pela Equação 1.

$$P = \frac{\rho A V^3}{2} \quad (1)$$

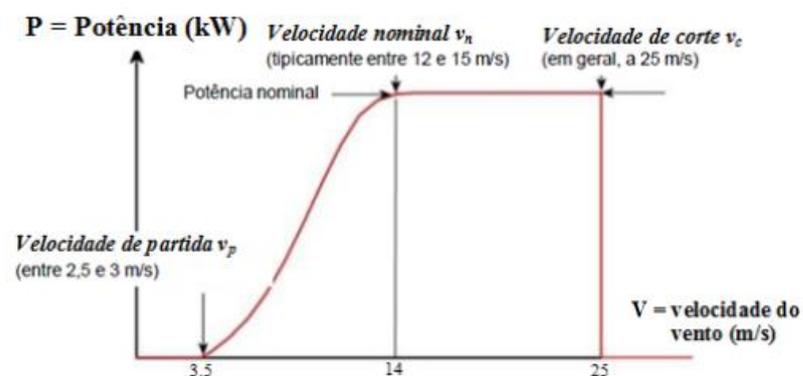
em que P é a potência do vento, ρ é a densidade do ar, A é a área de varredura do rotor e V é a velocidade do vento (SHAMSHIRBAND et al., 2014).

A velocidade é o fator mais significativo para o aproveitamento eólico, uma vez que a potência é proporcional ao cubo da velocidade do vento. Como exemplo, se a velocidade do vento duplicar, a potência terá um valor oito vezes maior.

Ressalta-se que cada aerogerador possui uma curva de potência diferente, pois esta varia de acordo com o modelo e tipo do equipamento. Com isso, é necessário escolher um modelo mais apropriado para as condições meteorológicas locais, em que a velocidade correspondente da potência nominal seja próxima às velocidades mais frequentemente observadas.

Um exemplo da curva de potência para turbinas eólicas é mostrado na FIGURA 6, que expressa qual a produção de energia elétrica por unidade de tempo (potência) para diferentes valores de velocidades do vento (PESSANHA et al., 2010 apud VARGAS, 2015).

FIGURA 6 – REPRESENTAÇÃO DA CURVA DE POTÊNCIA DE UMA TURBINA EÓLICA.



FONTE: Pessanha et al (2010) apud Vargas (2015).

Na figura acima (FIGURA 6), a potência (kW) está no eixo das ordenadas e a velocidade do vento (m/s) no eixo das abcissas. A velocidade inicial, ou de partida, é a velocidade mínima que o vento deve atingir para o aerogerador começar a gerar energia. Esse valor depende do tipo e modelo da turbina utilizada, mas varia, geralmente, de 2,5 a 3 m/s. Velocidades inferiores à inicial têm potência nula.

Velocidades de 3 a 12 m/s correspondem à curva do gráfico, a qual é referente a equação da potência do vento mostrada anteriormente (Equação 1), em que a potência é proporcional ao cubo da velocidade.

Chama-se velocidade nominal a velocidade localizada no ponto de inflexão do gráfico, geralmente com valor em torno de 12 m/s. Tal velocidade corresponde à potência nominal do aerogerador, que é a máxima potência produzida. Para velocidades superiores à nominal a potência permanece neste mesmo valor máximo, a qual é exibida pela linha reta horizontal do gráfico.

Há também a chamada velocidade de corte, que comumente é em torno de 25 m/s. Essa velocidade corresponde à velocidade máxima que um aerogerador pode funcionar por questões de segurança, para que o equipamento não danifique e desgaste. A partir dessa velocidade a potência é nula novamente.

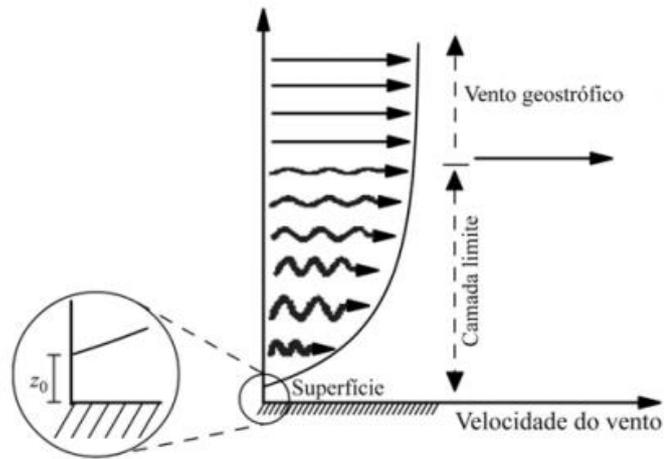
Tendo isso em vista, reforça-se a relevância de fazer um estudo sobre o regime de ventos da região, para que se possa selecionar e instalar um aerogerador que possua potência nominal compatível com a distribuição da velocidade da localidade.

2.1.1.2.3 Perfil da velocidade do vento

A CLS (Camada Limite Superficial), que está contida na CLA (Camada Limite Atmosférica), abrange desde o solo até 120 metros, aproximadamente. Grandes variações de algumas variáveis atmosféricas ocorrem nesta camada, como a velocidade do vento com a altura (LINARD, 2010).

A velocidade do vento é quase nula a alturas próximas à superfície e aproximadamente geostrófica (não acelerado e de direção horizontal) na atmosfera livre (acima da camada limite). Além disto, na camada limite o perfil da velocidade é aproximadamente logarítmico (MARTINS; GUARNIERI; PEREIRA, 2007), como ilustrado na FIGURA 7.

FIGURA 7 – PERFIL DA VELOCIDADE DO VENTO.



FONTE: MARTINS; GUARNIERI; PEREIRA, 2007.

A seguinte relação logarítmica pode ser utilizada para estimar a velocidade do vento em uma altura z , em condição de estabilidade neutra,

$$V(z) = \frac{u_*}{K} \ln\left(\frac{z}{z_0}\right) \quad (2)$$

onde $V(z)$ é a velocidade no nível z (m/s), u_* é a velocidade de corte (m/s), K é o coeficiente de Von Karman (considerado 0,40), z é a altura no eixo do aerogerador (m) e z_0 é a altura de rugosidade aerodinâmica (m), que depende das características da superfície (STULL, 1999).

A rugosidade do solo pode ser caracterizada pela vegetação, uso do solo e construções (CRESESB, 2008). Quanto mais rugoso for o solo, menor a velocidade associada e quanto mais próxima de zero for a rugosidade menor será a alteração da velocidade (COPEL, 2016). Em função disso, nos continentes os ventos são menos velozes que nos oceanos, devido a maior heterogeneidade da cobertura da superfície (MENDONÇA; DANNI-OLIVEIRA, 2007 apud SILVA, 2016).

Elementos topográficos, como vales, depressões, cristas e colinas, também alteram os ventos (TOMASINI, 2011). De acordo com Silveira (2007) a topografia pode alterar o módulo e a direção do vento nessas localidades devido ao desnível das áreas (MINUZZI, 2011).

2.2 REDES NEURAIS ARTIFICIAIS

Uma rede neural artificial (RNA) é um sistema de processamento de informações com capacidade de soluções de problemas adquirida por meio de aprendizagem, generalização e reconhecimento de padrões (VILLANUEVA, 2016). As redes neurais possuem, geralmente, alta capacidade de modelar problemas não lineares complexos, como é o caso das questões associadas às variáveis meteorológicas (SILVA; AMARAL; ARRUDA, 2004).

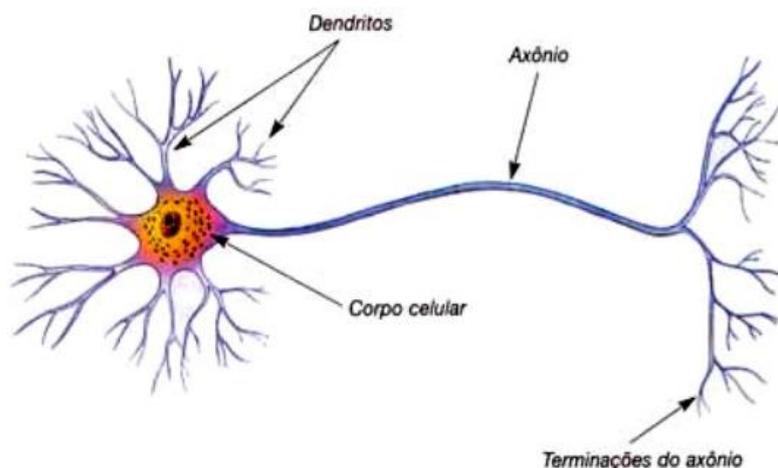
As RNAs são baseadas no cérebro humano, em que cada neurônio artificial possui estrutura semelhante ao de um neurônio biológico (COSTA, 2016). Para tanto, conhecer o funcionamento do cérebro humano pode auxiliar na compreensão das redes neurais artificiais.

2.2.1 Neurônio Biológico

O cérebro humano possui bilhões de neurônios, os quais são fundamentais para o funcionamento, raciocínio e comportamento do corpo humano. Os neurônios são as unidades principais do cérebro, os quais transmitem os impulsos nervosos ao cérebro (ROSSI, 2013).

A FIGURA 8 abaixo exemplifica a estrutura de um neurônio biológico.

FIGURA 8 – REPRESENTAÇÃO DE UM NEURÔNIO BIOLÓGICO.



FONTE: Hermano, 2009 apud REMES, 2013.

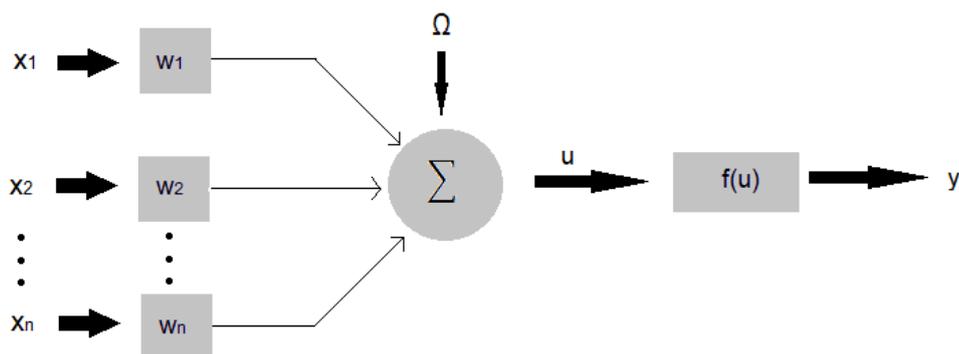
Os estímulos externos ou de neurônios vizinhos são recebidos através dos dendritos. No corpo celular é onde ocorre a coleta, o processamento e as combinações das informações recebidas pelos dendritos. Caso os impulsos gerados pelo corpo celular tenham intensidade suficiente, são emitidos pelo axônio para outras células, por meio das sinapses chamadas de junções de hiato. Sinapse é, então, a transmissão dos impulsos nervosos entre dois neurônios (ANDRADE, LUFT, ROLIM, 2004).

Como veremos no item seguinte, os neurônios artificiais funcionam de modo semelhante, em que as entradas da rede neural são os dendritos e as saídas são os axônios.

2.2.2 Neurônios Artificiais

O neurônio artificial é baseado no neurônio biológico. Como pôde ser visualizado na FIGURA 8, do neurônio biológico, há vários dendritos. Por esse motivo podem ser realizadas várias sinapses no mesmo instante de tempo. Deste modo, para os neurônios artificiais podem ser consideradas várias entradas, ou *inputs*, conforme na FIGURA 9 a seguir,

FIGURA 9 – ESQUEMA REPRESENTATIVO DO NEURÔNIO ARTIFICIAL.



Fonte: Elaborada pela autora.

onde x_1, x_2 a x_n são as entradas da rede (*inputs*); w_1, w_2 a w_n os pesos referentes às entradas; Σ é a função agregadora; Ω é o limiar de ativação; u é o potencial de ativação; $f(u)$ é a função de ativação e y é a saída (*output*).

As entradas da rede são definidas pelo usuário. Os pesos são diferentes para cada *input* e são responsáveis por ponderar cada entrada. A função agregadora (Σ) é dada pelo somatório, de 1 a n, do produto das entradas com os seus respectivos pesos. O limiar de ativação (Ω) indica qual o limite para que o resultado da função agregadora possa passar um sinal para a saída do neurônio artificial. O potencial de ativação (u) define se o neurônio produzirá um sinal excitatório (>0) ou inibitório (<0) (BRISK, 2016). Esse cálculo é feito com a subtração do valor da função agregadora com o valor do limiar de ativação (Equação 3). Na função de ativação é determinado se o resultado obtido é ou não relevante, isto é, se o neurônio será ou não ativado. Finalmente, a saída y corresponde ao valor final desse processo (BRANQUINHO, 2013), expresso pela Equação 4.

As equações utilizadas para os cálculos do potencial de ativação e do *output* estão, respectivamente, representadas a seguir.

$$u = \sum_{i=1}^n (x_i w_i) - \Omega \quad (3)$$

$$y = f(u) \quad (4)$$

2.2.3 Função de Ativação

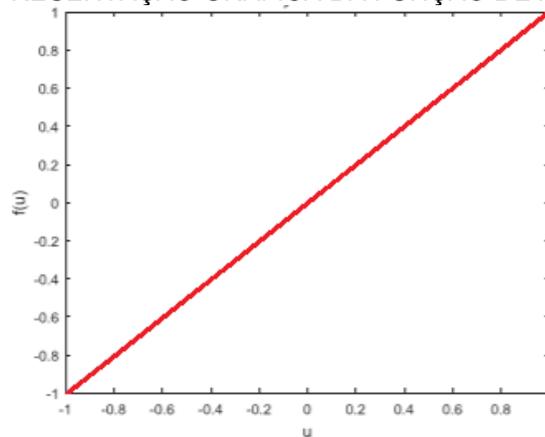
Como mencionado anteriormente, a função de ativação $f(u)$ é muito importante para o bom funcionamento da rede neural, uma vez que é a partir dela que são determinadas as respostas de cada neurônio. Podem ser divididas em dois grupos: lineares e não lineares. Alguns exemplos são mostrados a seguir.

- Função linear

A função linear, representada na FIGURA 10, é também conhecida como função identidade. A saída do neurônio não é alterada, ou seja, a saída terá valor igual ao do potencial de ativação.

$$f(u) = u \quad (5)$$

FIGURA 10 – REPRESENTAÇÃO GRÁFICA DA FUNÇÃO DE ATIVAÇÃO LINEAR.



FONTE: Adaptado NICOLAU (2016).

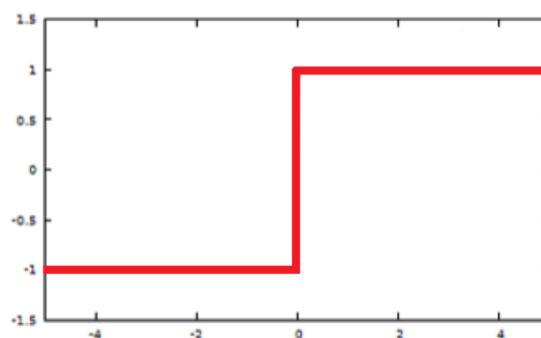
- Função degrau bipolar

A função degrau bipolar, representada na FIGURA 11, assume somente os valores de -1 e 1, conforme mostrado abaixo.

$$f(u) = \begin{cases} 1; & \text{se } u \geq 0 \\ -1; & \text{se } u < 0 \end{cases} \quad (6)$$

O gráfico dessa função é mostrado a seguir, em que se o potencial de ativação for maior ou igual a zero, o resultado da função de ativação será positivo. Caso contrário o resultado será negativo.

FIGURA 11 – REPRESENTAÇÃO GRÁFICA DA FUNÇÃO DE ATIVAÇÃO DEGRAU.



FONTE: Adaptado de CABRAL (2013).

- Função gaussiana

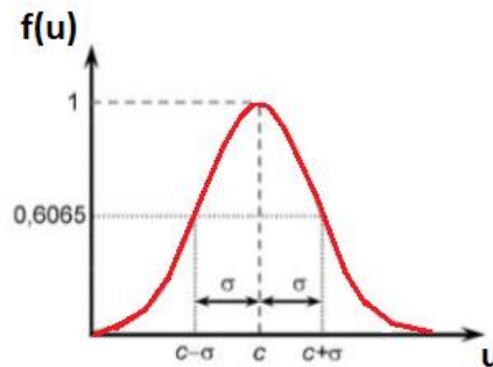
A função de ativação gaussiana é muito utilizada nas redes neurais de função de base radial (RBF) e é dada por:

$$f(u) = e^{-\frac{(u-c)^2}{2\sigma^2}} \quad (7)$$

onde c é o centro da função gaussiana e σ^2 é a variância, isto é, o quão distante está a curva do seu centro.

Uma representação da curva gaussiana está ilustrada na FIGURA 12 abaixo.

FIGURA 12 – REPRESENTAÇÃO GRÁFICA DA FUNÇÃO DE ATIVAÇÃO GAUSSIANA.



FONTE: Adaptado de SILVA; SPATTI; FLAUZINO (2010).

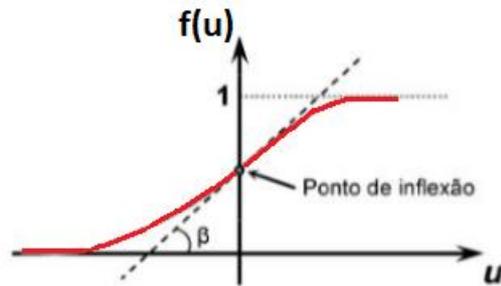
- Função sigmóide logística

A função sigmóide logística é dada por:

$$f(u) = \frac{1}{1 + e^{-\beta u}} \quad (8)$$

onde β é um valor positivo, relacionado com a inclinação da função em relação ao ponto de inflexão. A representação desta função é mostrada na FIGURA 13

FIGURA 13 – REPRESENTAÇÃO GRÁFICA DA FUNÇÃO DE ATIVAÇÃO SIGMÓIDE LOGÍSTICA.



FONTE: Adaptado de SILVA; SPATTI; FLAUZINO (2010).

2.2.4 Método Screening Regression

O método *screening regression* é utilizado para selecionar os preditores “ótimos” a partir de um conjunto maior de preditores potenciais (SILVA, 2007).

A influência de várias variáveis pode gerar a colinearidade, uma vez que essas podem refletir as mesmas informações. Assim, a técnica de *screening regression* seleciona os melhores preditores para o problema e descarta aqueles que são redundantes (Faraway, 2002 apud TSCHÖKE, 2011).

O método funciona, originalmente, com base no cálculo de regressão linear para todas as variáveis independentes selecionadas como potenciais predictoras, a fim de estipular a significância.

Neste trabalho, no entanto, empregou-se uma rede neural RBF para obter uma função não linear das variáveis independentes em lugar da regressão linear para identificar aquelas que seriam os preditores mais relevantes.

A cada passo é adicionada uma variável ao modelo (passo *forward*) e esta é escolhida de acordo com os resultados do menor valor da raiz do erro quadrático médio — REQM. Deste modo, as predictoras são ordenadas de forma decrescente em função da intensidade de relação com a velocidade do vento.

A cada entrada de uma variável ao modelo são reajustados os pesos e é recalculada a REQM do restante das variáveis individualmente em relação às que estão no sistema, até sejam inseridas no modelo todas as variáveis.

2.2.5 Arquitetura e treinamento de uma rede neural artificial

Os principais tipos de arquitetura empregados em RNAs são as *feedforward* de camada simples, as *feedforward* de múltiplas camadas e as recorrentes.

Segundo Santos (2018), a arquitetura *feedforward* de camadas simples possui apenas uma camada de neurônios, que corresponde à própria saída. Geralmente esse tipo é usado para as redes *Perceptron* e *Adaline*. A arquitetura *feedforward* de múltiplas camadas tem uma ou mais camadas ocultas (camadas intermediárias da rede, isto é, as camadas que estão entre a camada de entrada e a camada de saída). A exemplo de redes neurais que a utilizam cita-se a MLP (Perceptron de Múltiplas Camadas) e a RBF (Função de Base Radial). Já a arquitetura recorrente caracteriza-se pela realimentação da camada de entrada em outros neurônios pelos resultados obtidos na saída.

O treinamento de uma rede neural artificial é dito como o processo de aprendizagem desta. Durante esse processo são ajustados os pesos da rede e a função de ativação dos neurônios, para que seja estipulado um melhor resultado de saída (DSA, [2019]).

O treinamento pode ser agrupado em treinamento supervisionado e não-supervisionado. No treinamento supervisionado são utilizados pares de entrada e de saída. O valor do erro é calculado pela diferença entre o resultado da saída desejada (conhecida) com a saída fornecida pela rede. Os pesos e limiares são ajustados a cada passo da aprendizagem, até que o erro se torne satisfatório para o usuário (DOMINGUES, 2003). Tal ajuste pode ser realizado pelo algoritmo *backpropagation*.

Contudo, para o processo não-supervisionado não são fornecidos os valores de saída. A rede se desenvolve para criar representações internas e gerar novas classes (ou *clusters*) para os padrões de entrada. Assim, os pesos e limiares vão sendo ajustados ao mesmo passo da caracterização destas classes.

Um dos métodos de clusterização utilizado para a classificação dos dados é o algoritmo *k-means*, o qual realiza a separação dos dados em classes sem que haja a necessidade de uma classificação pré-existente. Inicialmente, são definidos valores aleatórios para os centros dos neurônios (*clusters*) e é selecionado o vetor dos dados de entrada. Em seguida, os dados semelhantes são agrupados na classe que possui menor distância a algum dos centros aleatórios. Posteriormente, o algoritmo calcula novos centros das classes, com base na distância média dos dados nelas agrupados.

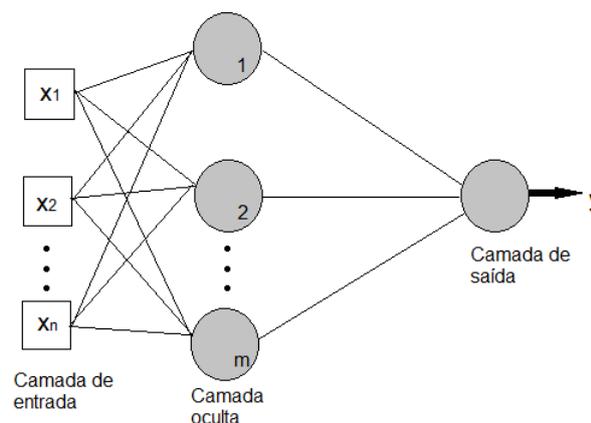
Um novo cálculo entre as distâncias dos dados aos centros é feito e os dados são reagrupados. Novamente, os centros são recalculados a partir das distâncias médias dos dados nas classes. O ciclo se repete até o momento em que os dados não migrem de classe, isto é, até que os centros estejam bem definidos (VARELLA & QUADRELLI, 2017). É importante mencionar que o usuário define o número de *clusters* a ser criado, sendo este o número de neurônios na camada oculta. Deste modo, o valor da resposta do campo receptivo gaussiano é maior ao passo que a distância entre o centro do agrupamento e dos dados de entrada for menor.

Por fim, pode-se afirmar que a RNA aprende através de um processo iterativo de modificação dos pesos de interligação, a partir dos estímulos fornecidos pelo ambiente.

2.2.6 A RNA de Função de Base Radial

As RNA de função de base radial, ou RBF (*radial basis function*) costumam apresentar bons resultados para problemas complexos, além de possuírem aprendizado relativamente rápido (COELHO, 2007). São redes com arquitetura *feedforward* com múltiplas camadas, conforme ilustrado a seguir. Essa rede é muito útil para a solução de problemas não-lineares, como é o caso de previsões de velocidade do vento.

FIGURA 14 – ESQUEMA REPRESENTATIVO DA ESTRUTURA DE UMA REDE NEURAL RBF.



Fonte: Elaborada pela autora.

A camada de entrada é onde ocorre o recebimento dos dados pelos neurônios. A camada oculta trata os dados recebidos com uma função não-linear. A camada de saída faz a combinação linear dos valores resultantes da camada oculta.

Geralmente a RBF possui apenas uma camada oculta, assim como mostrado na FIGURA 14, em que a função de ativação típica é a gaussiana (ROSA, 2011). Essa camada oculta pode possuir diversos neurônios, em que o número “ótimo” é descoberto através de testes.

A camada de saída pode possuir mais de um neurônio e esse número dependerá de quantas variáveis-respostas o usuário necessita.

2.2.6.1 Treinamento da rede neural artificial RBF

O treinamento da rede neural artificial RBF acontece em dois estágios. O primeiro é o treinamento não-supervisionado, o qual ocorre na camada oculta, e o segundo é o treinamento supervisionado, com ocorrência na camada de saída.

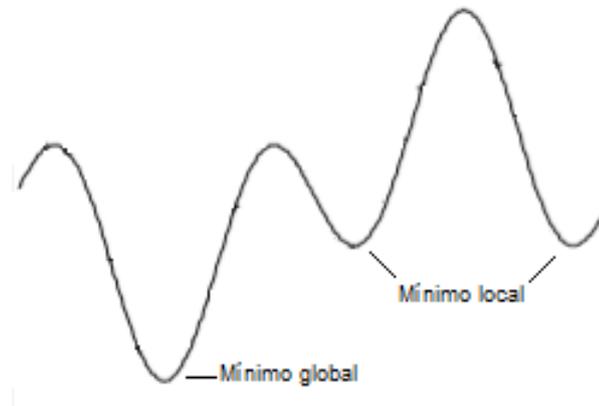
Para o primeiro estágio deve ser escolhido o número de neurônios, que irá corresponder ao número de *clusters* (ROSA, 2011). Então, todo o processo descrito a partir da FIGURA 9 ocorre.

Já no segundo estágio é utilizada a abordagem supervisionada, em que são recebidos os valores da função de ativação gaussiana obtidos do primeiro estágio de treinamento (BRISK, 2016), para determinar os pesos da camada de saída (ROSA, 2011). Nessa fase, adota-se a função de ativação linear no neurônio de saída.

Esse treinamento ocorre por épocas e é finalizado quando os pesos e limiares estejam estáveis e o erro associado convirja para um mínimo. Alguns dos erros calculados e utilizados como métrica são apresentados na seção 3.3.4 (SILVA, 1998). Outro critério de parada é com a percepção de que a rede está perdendo a capacidade de generalização, processo este chamado de *overtraining*. Isso ocorre quando a rede passa a “memorizar” os padrões dos dados e até os ruídos presentes nestes (SEVERO, 2010). Sabe-se que atingiu o *overtraining* quando o erro começa a aumentar na etapa de teste, assim como referido nos parágrafos subsequentes.

Os mínimos da função erro podem ser locais ou global, conforme mostrado na FIGURA 15, o qual é um exemplo de uma curva de uma função de erros. O ideal é encontrar o mínimo global, o qual indica o menor valor de erro possível para a função (valor “ótimo”). Porém, muitas vezes são descobertos os mínimos locais.

FIGURA 15 – REPRESENTAÇÃO DE UMA FUNÇÃO DE ERROS CONTENDO MÍNIMOS LOCAIS E GLOBAL.



FONTE: Modificado de ZUBEN (2009).

Portanto, para que seja possível realizar um bom treinamento, para gerar bons resultados de saída e sem que haja *undertraining* (quando é apresentado um número insuficiente de dados e a rede não consegue aprender o problema eficazmente) ou *overtraining*, os dados pretéritos experimentais são divididos aleatoriamente em três grupos, que são do treinamento, teste e validação.

A maior parte dos dados são destinados para o treinamento (cerca de 90%) e estes devem ser significativos no todo, para que a rede possa aprender com todas as variações e eventos extremos.

A segunda etapa é a de teste (realizada após cada época do treinamento), em que são apresentadas à rede aproximadamente 5% dos dados históricos, para que seja estimado o valor do erro, o qual é previsto a partir da comparação do resultado modelado com o observado. Com as épocas de treinamento, esses valores de erro tendem a diminuir até que se encontre o menor valor possível.

Finalmente, quando são encontrados os melhores ajustes para os pesos, os outros 5% dos dados são apresentados à rede para a etapa de validação. Essa é caracterizada pela comparação dos dados obtidos com os verdadeiros (medidos pela estação anemométrica) e, assim, verifica-se o quanto a rede foi capaz de aprender sobre o problema, isto é, sobre a acurácia do treinamento realizado anteriormente.

2.3 ESTUDOS REALIZADOS SOBRE A PREVISÃO DA VELOCIDADE DO VENTO

A classificação temporal das previsões não é padronizada, podendo-se encontrar diferentes classes para o mesmo horizonte de previsão (FUJISE, 2018). Neste trabalho será considerado o horizonte de curto prazo, o qual a previsão varia de 1 a 72 horas.

Na TABELA 1 há a classificação adotada para o tempo de previsão com seu respectivo horizonte (SILVA, 2017; HIRUMA, 2016; FUJISE, 2018).

TABELA 1 – RELAÇÃO DO TEMPO DE PREVISÃO PARA CADA HORIZONTE DE PREVISÃO.

Horizonte de previsão	Tempo de previsão
Curtíssimo prazo	Até 1 hora
Curto prazo	1 a 72 horas
Médio prazo	3 a 7 dias
Longo prazo	Mais de 7 dias

A previsão de curto prazo auxilia no planejamento energético, sendo importante a previsão da velocidade do vento para uma maior segurança energética e inclusão da fonte renovável em questão na matriz elétrica (SILVA, 2017; HIRUMA, 2016; FUJISE, 2018).

Os estudos de Silva (2017); Hiruma (2016) e Fujise (2018) também consideraram a mesma variação temporal para os horizontes de previsão listados na TABELA 1 no que se refere às previsões de vento.

Pessanha, Castellani e Lima (2011) realizaram a previsão de curto prazo empregando, entre os métodos, uma rede neural artificial. Os autores analisaram a velocidade do vento na localidade de São Martinho da Serra a 50 metros de altura, utilizando dados do projeto SONDA. A previsão tem como horizonte uma hora à frente, tendo como preditores a própria velocidade do vento com alguns atrasos temporais. Como resultado, obteve-se uma REQM (Raiz do Erro Quadrático Médio) de 1,1336 m/s e um EMA (Erro Médio Absoluto) de 0,8373 m/s.

Santos (2019) realizou a previsão da velocidade do vento a 50 metros em relação ao nível do solo na região agreste de Alagoas. O autor empregou o modelo atmosférico WRF (*Weather Research and Forecasting*) em conjunto com a rede neural artificial NARX para a previsão 24 horas à frente. Como resultado, obteve uma REQM de 1,18 m/s.

Li e Shi (2010) propuseram a previsão da velocidade dos ventos através de três diferentes redes neurais artificiais (ADALINE, MLP e RBF), para a previsão de uma hora à frente. O local de estudo fica no estado de Dakota do Norte, nos EUA, e os dados de velocidade foram medidos a uma altura de 10 metros do solo. Os modelos não apresentaram muita variação entre si. A rede ADALINE teve como EMA valores entre 0,965 e 1,163 m/s, a MLP valores entre 0,945 e 1,176 m/s e a RBF obteve EMA entre 0,989 e 1,112 m/s. Do mesmo modo, calculou-se o REQM, em que os resultados foram entre 1,271 e 1,485; 1,254 e 1,469; e 1,294 e 1,444, para a ADALINE, MLP e RBF, respectivamente.

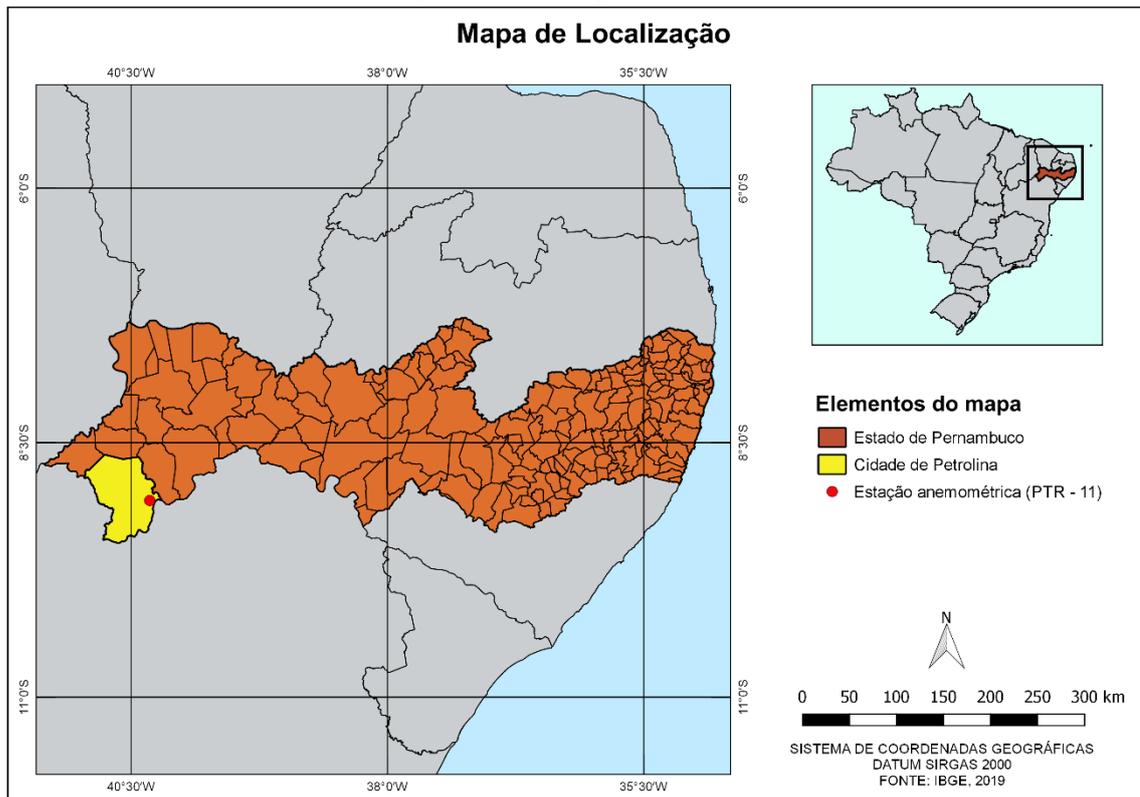
Previsões da velocidade do vento utilizando uma RNA MLP em horizontes de 1 a 6 horas para resolução de 1 hora e horizontes de 1 a 18 horas para resolução de 3 horas foram executadas por Hiruma (2016). O local de estudo foi Palmas, no Paraná. Os dados foram divididos entre o período quente (janeiro a fevereiro) e o período frio (julho a agosto). Para a resolução de 1 hora, o resultado da previsão para o período quente (frio) foi: para uma hora a REQM foi de 1,055 (1,088) m/s, EMA de 0,801 (0,827) m/s. Para 3 horas à frente a REQM foi de 1,764 (1,927) m/s e o EMA de 1,370 (1,482) m/s. Para 6 horas à frente a REQM foi de 2,284 (2,423) m/s, enquanto o EMA foi de 1,800 (1,931) m/s. Já para a resolução de 3 horas a previsão de 3 horas à frente foi mais acurada, uma vez que para o período quente (frio) esses valores foram de 1,445 (1,567) m/s e 1,151 (1,203) m/s para a REQM e EMA, respectivamente. O mesmo ocorreu para o horizonte de 6 horas, em que a REQM foi de 2,125 (2,215) m/s e o EMA 1,641 (1,755) m/s. Para a previsão de 12 horas os resultados foram o seguinte: 2,454 (2,457) m/s para a REQM e 1,950 (1,988) m/s para o EMA. Finalmente, para a previsão 18 horas à frente, o autor obteve 2,175 (2,477) m/s na REQM e 1,786 (2,010) m/s no EMA. Destaca-se que a altura em que os ventos foram medidos foi 44 metros.

3 MATERIAIS E MÉTODOS

3.1 ÁREA DE ESTUDO

A área de estudo escolhida foi Petrolina, localizada no estado de Pernambuco. Na FIGURA 16 tem-se o mapa de localização do estado de Pernambuco com destaque para o município de Petrolina, onde está localizada a torre anemométrica do projeto SONDA, cujos dados medidos foram utilizados para a elaboração deste trabalho. A estação, que possui sigla PTR – 11, está representada pelo símbolo circular vermelho (FIGURA 16).

FIGURA 16 – MAPA DE LOCALIZAÇÃO DA ESTAÇÃO ANEMOMÉTRICA DO PROJETO SONDA.



FONTE: Elaborado pela autora.

A FIGURA 17 ilustra a estação anemométrica de Petrolina, com anemômetros a 10, 25 e 50 metros, localizada nas coordenadas 09°04'08" S e 40°19'11" O, a uma altitude de 387 metros.

FIGURA 17 – FOTO DA TORRE ANEMOMÉTRICA DE PETROLINA.



FONTE: SONDA (2006).

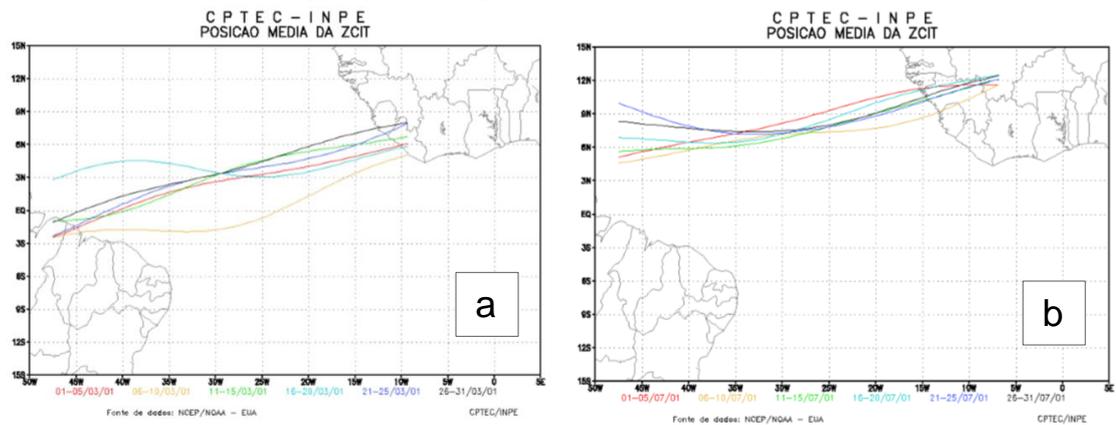
O município está localizado no semiárido do nordeste do Brasil e é caracterizado pela irregularidade e escassez pluviométrica (SONDA, 2006).

As chuvas são mais intensas de janeiro a abril, em consequência do deslocamento da Zona de Convergência Intertropical (ZCIT) em direção ao hemisfério sul, que influencia na convergência da umidade e da convecção local. Neste mesmo período, a umidade relativa também é maior. Já no inverno, quando a ZCIT está deslocada para o hemisfério norte, a precipitação mensal é pequena (SONDA, 2006).

A ZCIT é onde ocorre o encontro dos ventos alísios e fica próxima da faixa equatorial, deslocando-se no sentido do hemisfério mais quente ao longo do ano. Durante o verão no hemisfério sul esta zona se move no sentido sul, ao mesmo tempo que a massa de ar polar atlântica se aproxima do polo. Assim, o nordeste brasileiro é afetado pela ZCIT. Com a maior radiação solar incidente no início do ano, há um maior aquecimento (provocando baixas pressões na superfície), resultando em mais evaporação do oceano e, conseqüentemente, em um aumento da umidade. Por ser uma região de convergência dos ventos, há o favorecimento do movimento ascendente, carregando o ar quente e úmido para níveis mais altos da atmosfera, ocasionando na formação de nuvens e na precipitação mais intensa nesta época do ano (CPTEC, 2018).

A FIGURA 18-a e a FIGURA 18-b exemplificam a localização da ZCIT no Nordeste no verão e no inverno.

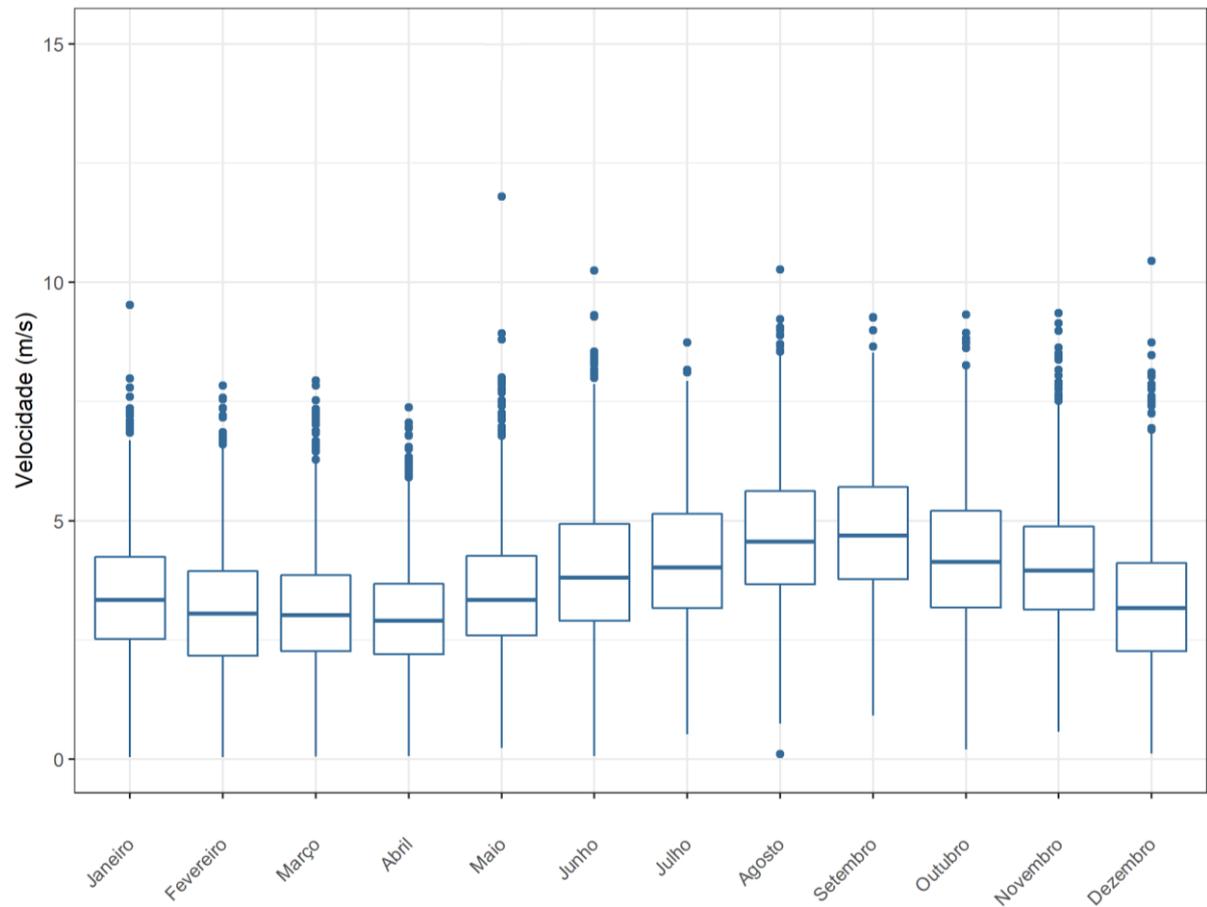
FIGURA 18 – REPRESENTAÇÃO DA POSIÇÃO MÉDIA DA ZCIT NO a) VERÃO b) INVERNO.



FONTE: SILVA (2003).

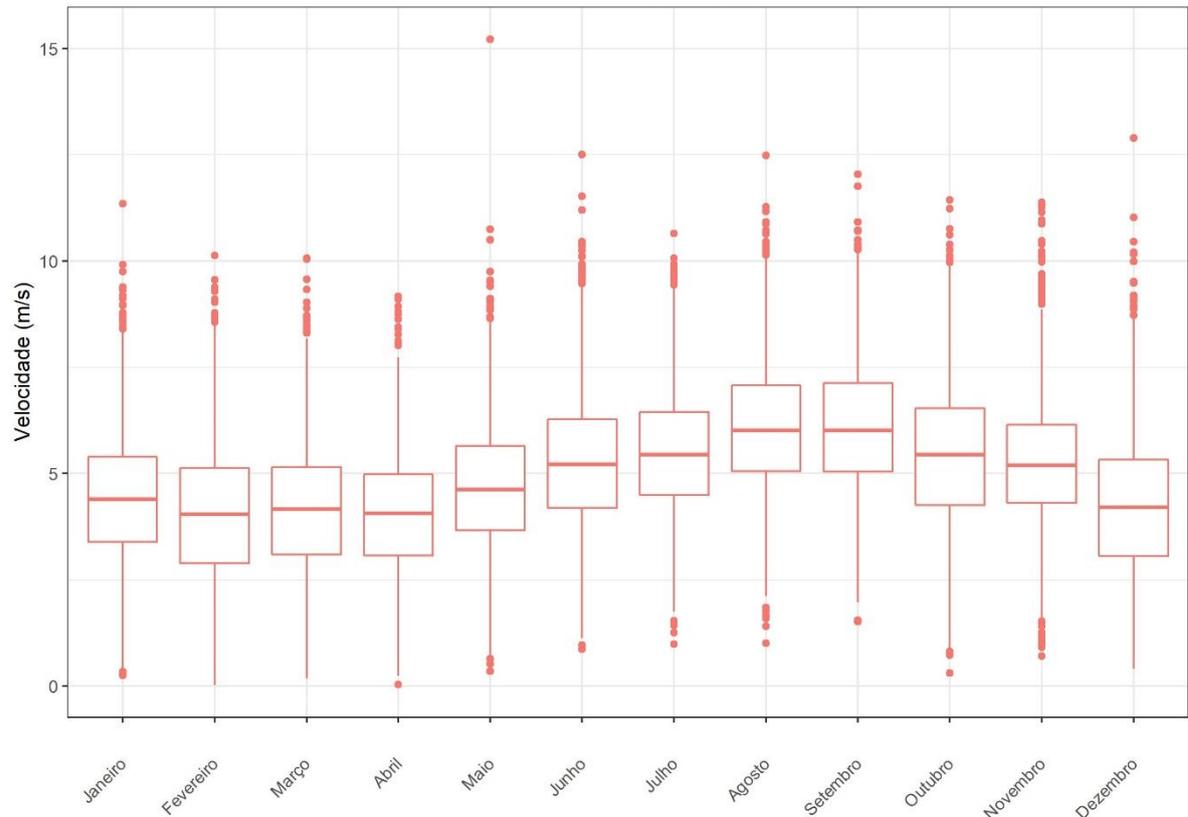
Para uma melhor compreensão do regime de ventos na região de estudo foram elaboradas a FIGURA 19 e a FIGURA 20, as quais se referem às alturas de 25 e 50 metros a partir do nível do solo, respectivamente. Ambas as figuras foram feitas considerando as medições das velocidades do vento dos anos de janeiro de 2007 a dezembro de 2010.

FIGURA 19 – VALORES MENSAIS DA VELOCIDADE DO VENTO A 25 METROS.



Pela FIGURA 19 observa-se que as maiores velocidades do vento são observadas nos meses de agosto, setembro e outubro, enquanto as velocidades mais baixas são verificadas nos meses de fevereiro, março e abril.

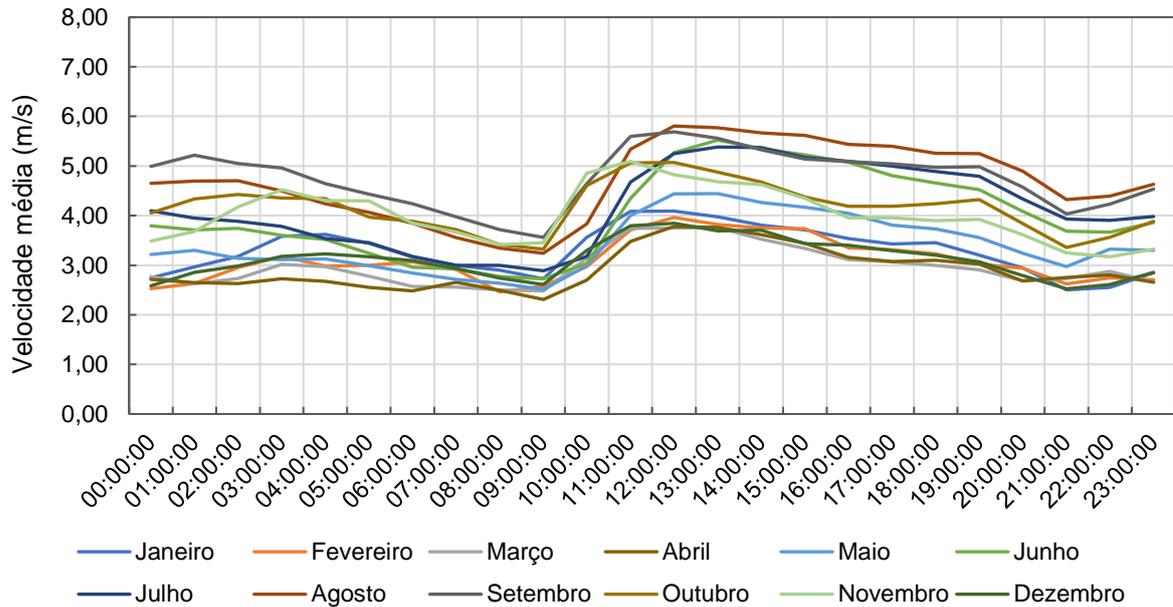
FIGURA 20 – VALORES MENSAIS DA VELOCIDADE DO VENTO A 50 METROS.



Já para a altura de 50 metros (FIGURA 20), nota-se que, conforme já era esperado (FIGURA 7) as velocidades são superiores às de 25 metros, em todos os meses. De forma semelhante ao mostrado na FIGURA 19, os meses com as maiores velocidades são agosto; setembro e outubro, e os meses com as menores velocidades são fevereiro; março e abril.

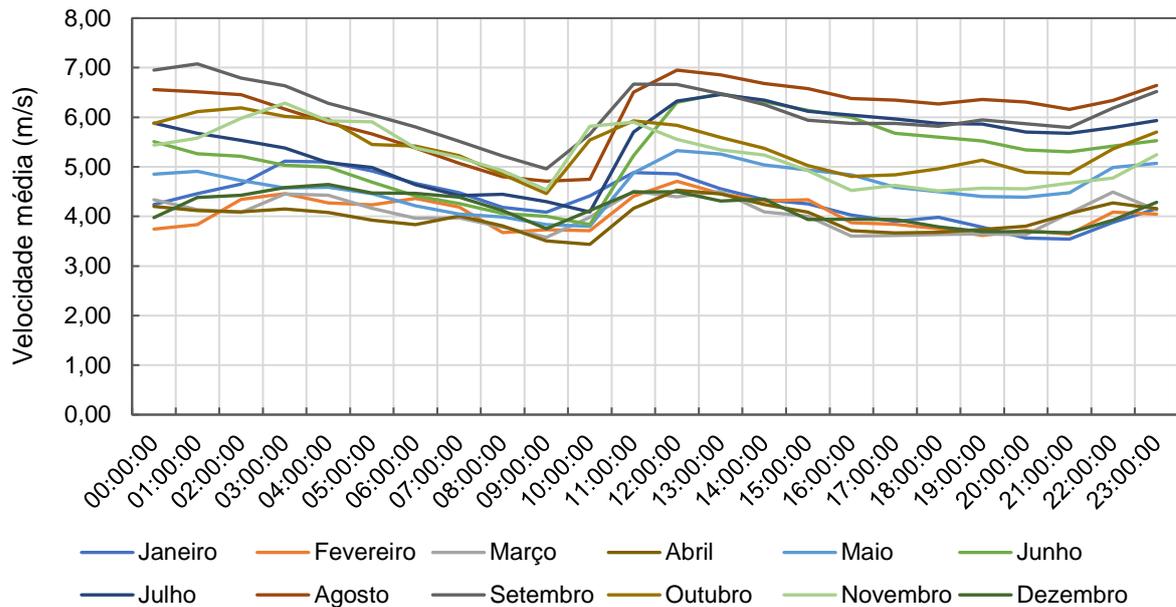
Como um dos objetivos deste trabalho é a previsão da velocidade do vento em diferentes horizontes de tempo dentro de 24 horas (1, 3, 6, 12, 18 e 24 horas à frente), calculou-se as médias horárias por mês do ano, a fim de avaliar o comportamento diário da velocidade do vento (FIGURA 21 e FIGURA 22).

FIGURA 21 – CICLO DIÁRIO DA VELOCIDADE DO VENTO A 25 METROS.



Pela FIGURA 21 nota-se que a média do ciclo diário da velocidade do vento na altura de 25 metros é semelhante para todos os meses do ano. Destaca-se que 09 horas da manhã é o horário em que a média histórica diária decresce consideravelmente, atingindo a mínima velocidade diária na maioria dos meses. Das 11 às 13 horas é quando ocorrem os picos de velocidade do vento e às 21 horas a velocidade volta a diminuir em todos os meses, sendo este o horário que alguns meses obtiveram as menores velocidades medidas.

FIGURA 22 – CICLO DIÁRIO DA VELOCIDADE DO VENTO A 50 METROS.



Na FIGURA 22 percebe-se que para a altura de 50 metros também há um ciclo semelhante entre os meses do ano. Os mínimos do gráfico ocorrem nas horas 08, 09, 10 e 21; e os máximos nas horas 01, 12 e 13.

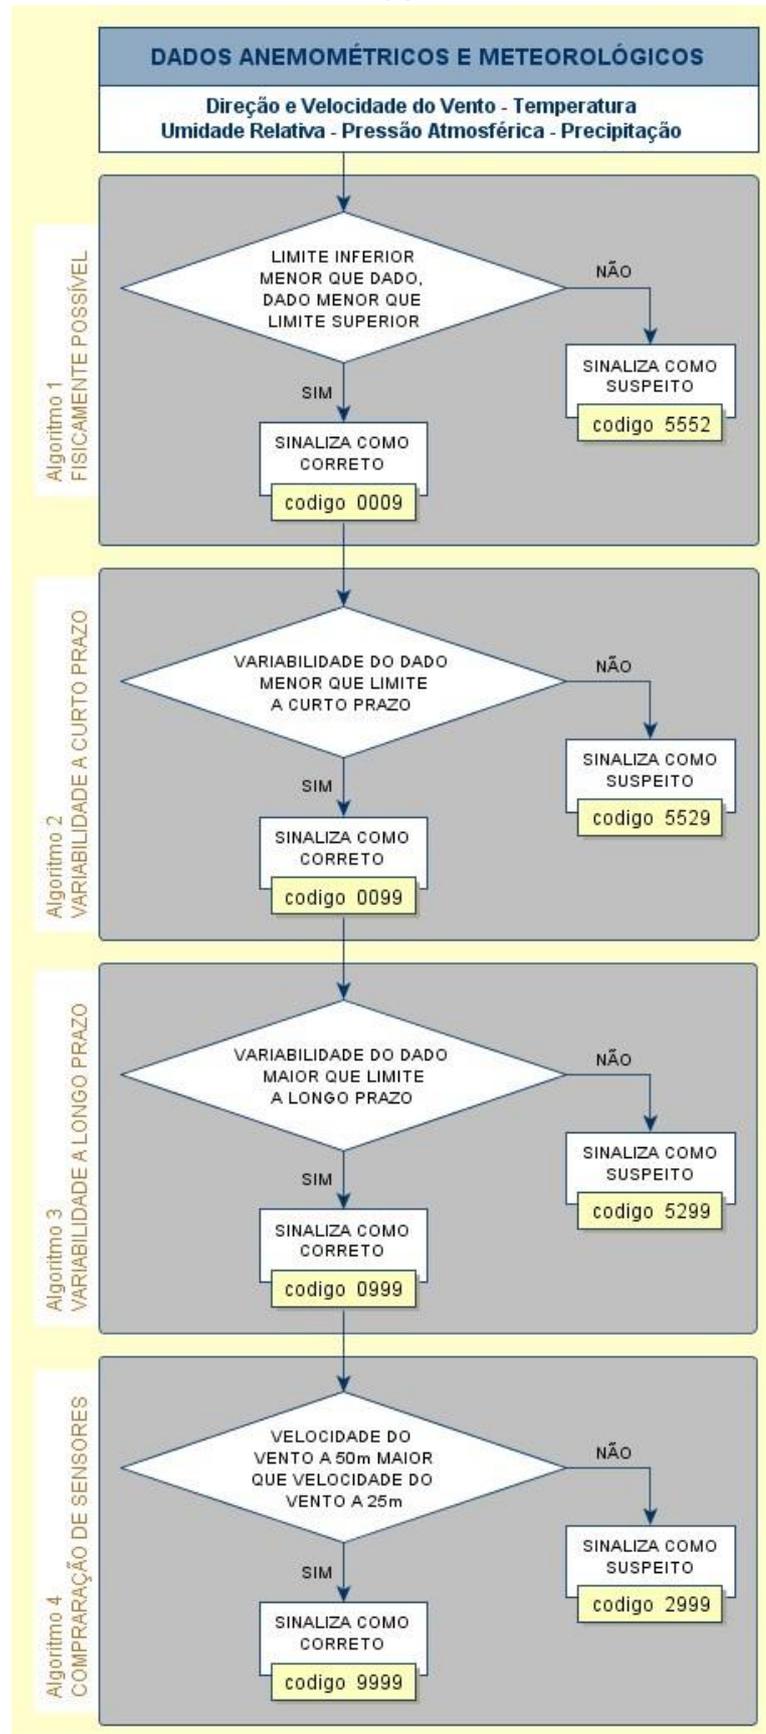
3.2 BASE DE DADOS METEOROLÓGICAS

Os dados utilizados neste trabalho foram obtidos da torre anemométrica em Petrolina (Pernambuco) através do projeto SONDA, que visa desenvolver pesquisas em clima e meteorologia, com enfoque para as energias solar e eólica. Esse projeto foi elaborado pelo INPE (Instituto Nacional de Pesquisas Espaciais) e tem como propósito a implementação de uma infraestrutura física e de recursos humanos para a montagem de um sistema de coleta de dados e melhoramento da base de dados no Brasil (SONDA, 2006).

Os dados da estação anemométrica de Petrolina estão disponíveis para os doze meses do ano e contemplam o período de janeiro de 2007 a dezembro de 2010. As variáveis disponíveis são a direção do vento (10, 25 e 50 metros de altura), temperatura do ar (superfície, 25 e 50 metros de altura), velocidade do vento (10, 25 e 50 metros de altura), radiação, umidade relativa, pressão atmosférica e precipitação. Os registros das três primeiras variáveis citadas são obtidos de 10 em 10 minutos e o restante delas são dados medidos de 1 em 1 minuto.

São, também, disponibilizados arquivos referentes à confiabilidade dos dados que foram medidos, os quais são submetidos a um teste de validação de quatro etapas, onde há a sinalização dos dados suspeitos, gerando um código de validação para cada dado que tenha sido coletado. A aprovação de cada etapa é um requisito obrigatório para sequência do processo. As etapas dos algoritmos para a geração destes códigos são apresentadas na FIGURA 23.

FIGURA 23 – ESQUEMA REPRESENTATIVO DAS ETAPAS DA VALIDAÇÃO DOS DADOS MEDIDOS.



FONTE: SONDA (2006).

Para exemplificar as etapas do processo de validação, a velocidade do vento a 25 metros será utilizada como exemplo.

O algoritmo 1 avalia o dado como suspeito quando o valor é fisicamente impossível. No caso da velocidade do vento o dado será suspeito caso o valor medido, em um determinado horário, seja inferior a 0 m/s, por exemplo. O código será 5552, em que o número 5 indica que os algoritmos 2, 3 e 4 não foram executados e o número 2 indica que o dado foi considerado suspeito na primeira etapa.

O algoritmo 2 indica quando o evento é extremamente raro. Na velocidade do vento raramente ocorrem variações inferiores a 0,1 m/s considerando 3 horas consecutivas, então se isso ocorrer o dado será suspeito. O código será 5529. O número 2 ocupa a terceira posição (da esquerda para a direita) devido ao erro ter ocorrido na segunda etapa do processo. O número 9 indica que o dado foi aprovado na primeira etapa de validação (algoritmo 1).

O algoritmo 3 quando a evolução temporal não condiz com o esperado para aquela variável. Assim, de forma semelhante ao processo anterior, o dado é suspeito quando a variação for inferior a 0,5 m/s em um período de 12 horas consecutivas. O código será 5299, pois o dado foi validado nos algoritmos 1 e 2, mas no algoritmo 3 deu erro.

Por fim, o algoritmo 4 é avaliado apenas quando a variável for a velocidade do vento a 25 ou a 50 metros. O valor será considerado suspeito quando este for inconsistente com medidas apresentadas por outras variáveis da mesma estação, isto é, quando a velocidade do vento a 25 metros for maior que a velocidade do vento a 50 metros para um mesmo instante de tempo. O código será 2999 (dado aprovado pelos 3 primeiros algoritmos, mas reprovado no algoritmo 4).

O conjunto de dados e de validação anteriormente mencionados podem ser encontrados no site do projeto SONDA, do INPE, através do seguinte endereço eletrônico <<http://sonda.ccst.inpe.br/basedados/petrolina.html>>.

3.3 METODOLOGIA

3.3.1 Análise dos dados

As variáveis a serem consideradas para a previsão do vento em Petrolina são a direção do vento (10, 25 e 50 metros de altura), temperatura do ar (superfície, 25 e 50 metros de altura), velocidade do vento (10, 25 e 50 metros de altura), radiação, umidade relativa, pressão atmosférica e precipitação de chuva. Os dados que serão analisados estão disponíveis desde a data de janeiro de 2007 a dezembro de 2010.

Essa análise e seleção deverá atender dois critérios: não pode haver dados faltantes (sem medição) e os dados têm que ter passado pelo teste de validação apresentado no item 3.2. Desta forma, só são selecionadas para a próxima etapa (item 3.3.2) as variáveis que possuírem um número significativo de dados aprovados (cerca de 32.000) após as etapas de validação, isto é, que possuírem os seguintes códigos descritos na TABELA 2.

TABELA 2 – RELAÇÃO DOS CÓDIGOS DAS VARIÁVEIS SELECIONADAS APÓS AS ETAPAS DE VALIDAÇÃO.

Código dos dados válidos	Variáveis meteorológicas
9	Umidade Relativa
99	Pressão Atmosférica
999	Temperatura, Direção do Vento a 10, 25 e 50 metros, Precipitação, Radiação, Velocidade do Vento a 10 metros
9999	Velocidade do Vento a 25 metros, Velocidade do Vento a 50 metros

3.3.2 Seleção de preditores

Inicialmente, será realizada a etapa preliminar, a qual consiste na identificação dos potenciais preditores através das suas correlações lineares com a velocidade do vento.

Essa etapa seleciona as variáveis que apresentam maior relação com a velocidade do vento, isto é, as variáveis que se espera que irão influenciar em uma melhor qualidade na previsão.

A correlação utilizada é chamada de correlação cruzada, em que é avaliada a similaridade entre duas variáveis em função de um atraso de uma delas (GONÇALVES, 2018). Para o presente trabalho, o comportamento de um preditor (na hora “X”) pode influenciar a velocidade do vento em determinado momento futuro à hora “X”.

De modo geral, essa correlação mostra-se útil na identificação de possíveis preditores (com atrasos temporais) para a previsão da velocidade do vento.

O critério arbitrado após a observação dos resultados das correlações foi que os preditores fossem selecionados com base naqueles que possuíssem correlação linear igual ou superior a 0,4 com a variável de interesse (velocidade do vento a 25 ou velocidade do vento a 50 metros).

Em seguida, será utilizado o método *screening regression* para a seleção dos preditores “ótimos”, o qual foi apresentado no item 2.2.4. A seleção dos preditores deste trabalho seguirá o método *forward screening regression*, em que, a cada passo, será adicionada uma variável no modelo, até que todas sejam inseridas.

O primeiro preditor inserido é o que apresentar maior significância para a previsão da velocidade do vento (menor valor resultante da Raiz do Erro Quadrático Médio (REQM)), enquanto o último é o que possuir menor significância (maior valor da REQM). Essa análise é realizada a partir de um programa escrito na linguagem de programação Fortran e que funciona no sistema operacional Linux.

Ao mesmo tempo em que são determinadas as variáveis preditoras pelo método *screening regression* são feitas simulações para a definição do número mais adequado de neurônios na camada oculta. É importante realizar testes com diferentes números de neurônios ocultos para que o processo de previsão seja o mais satisfatório possível e para que o esforço computacional não seja maior do que o necessário.

Para isso, diversas simulações foram realizadas de acordo com o tempo de previsão requerido. Assim, os experimentos abrangem simulações de 1, 3, 6, 12, 18 e 24 horas à frente para a previsão da velocidade do vento a 25 metros e a 50 metros. Para cada uma destas simulações foi determinado experimentalmente o número ótimo de neurônios na camada oculta, que podem variar de horizonte para horizonte. Esse número ótimo foi selecionado a partir da comparação dos resultados da REQM dos experimentos.

Após concluída essa etapa, com o número de neurônios na camada oculta definidos e com a lista decrescente dos preditores mais importantes para o modelo,

foram determinadas quantas e quais seriam as variáveis preditoras que foram inseridas como entrada do modelo.

3.3.3 Treinamento da rede neural

Para o treinamento da rede neural artificial RBF foram utilizados três programas, os quais tiveram os códigos computacionais elaborados e disponibilizados pelo professor Dr. Ricardo Carvalho de Almeida.

O primeiro programa retirava da base de dados de entrada as linhas que possuíam dados inválidos, isto é, que não foram aprovados pelos algoritmos de validação (base de Dados METEOROLÓGICAS 3.2). Deste modo, foram selecionados somente os dados válidos dentre as variáveis selecionadas como preditoras de entrada.

Os dados restantes foram separados na proporção 1:9 para os próximos processos. Para o grupo treinamento-teste-validação foram utilizados 90% da base de dados, enquanto para o processo de operação da rede foram utilizados 10%. Os 10% separados para a operação da rede correspondem as datas de 01/09/2010 às 00:00 até 31/12/2010 às 23:00, as quais são a parte final da base de dados.

Em seguida, utilizou-se o programa referente à etapa de treinamento, teste e validação (correspondente aos 90% dos dados mencionados anteriormente). Destes dados selecionados para essa fase, determinou-se que 90% seriam usados para o treinamento, 5% para os testes e os outros 5% para a validação do treinamento. Ressalta-se que a divisão dos dados nestas porcentagens é feita de modo aleatório pela rede neural artificial.

O treinamento é iniciado e a cada época uma parte do conjunto de testes é processado, obtendo-se o erro quadrático médio na camada de saída. A comparação deste erro com o erro obtido na época anterior é feita, e caso o erro atual seja menor esse conjunto de sinapses é salvo. Caso seja maior, o conjunto de sinapses e das posições dos *clusters* anterior é utilizado, pois é dado como o conjunto com as melhores propriedades de generalizações. O número de épocas para o ajuste dos pesos é de 5.000.

Com os pesos ajustados são apresentados os 5% dos dados da validação do treinamento à rede. A comparação dos dados obtidos com os verdadeiros é feita a partir da métrica estatística de erros (seção 3.3.4).

Por fim, foi executado o terceiro programa, referente à operação da rede neural. Os 10% dos dados separados para esta etapa (mencionados no terceiro parágrafo) nunca foram apresentados para a rede neural artificial RBF até este momento. Assim, nessa etapa é visto se a rede foi capaz de aprender ou não durante a fase anterior, de treinamento. Os resultados são apresentados através dos erros estatísticos mostrados na seção seguinte.

Ressalta-se que cada um dos experimentos foram realizadas 10 iterações, chamada validação cruzada. Como os dados são separados aleatoriamente na fase de treinamento-teste-validação, pode ocorrer de a rede neural não aprender todos os cenários que existem, não sendo capaz de representar todo o conjunto de dados que retratam os eventos que ocorrem na natureza. Isto posto, na validação cruzada a rede separou o conjunto de dados em 10 e, então, foi realizado o processo de treinamento-teste-validação para cada iteração, a fim de o modelo ser apresentado a diferentes cenários de amostragem. Na mesma linha, os pesos sinápticos são iniciados com valores aleatórios e, dessa forma, são gerados diferentes desempenhos ao final de cada iteração. Neste trabalho foi considerado como resultado final do processo a média dos erros resultantes de cada etapa da validação cruzada.

3.3.4 Análise estatística dos resultados

As métricas estatísticas são empregadas a fim de validar os experimentos de previsão. Os índices utilizados neste trabalho foram o erro médio absoluto (EMA), a Raiz do Erro Quadrático Médio (REQM), a correlação de Pearson (Correl), e o erro percentual médio (EPM).

Nas seguintes formulações as variáveis V_{obs} , V_{mod} e n representam o valor observado, o valor modelado e o número total de dados, respectivamente.

a) Erro médio absoluto (EMA)

$$EMA = \frac{\sum_1^n |V_{mod} - V_{obs}|}{n} \quad (9)$$

O erro absoluto indica a diferença média entre o valor modelado e o valor observado. Quanto maior esse valor, maior a incerteza sobre a medição, isto é, pior a qualidade dos dados que foram simulados.

b) Raiz do Erro Quadrático Médio (REQM)

$$REQM = \sqrt{\frac{\sum_1^n (V_{mod} - V_{obs})^2}{n}} \quad (10)$$

A raiz do erro quadrático médio indica o quão acurado é o resultado em comparação à realidade. Quanto maior o seu valor, menos acurado. Da mesma forma, quanto mais próximo de zero for o resultado do erro, mais acurado foi o experimento.

A REQM é muito utilizada nos estudos, porém recebe algumas críticas por ser sensível aos valores discrepantes (*outliers*) (EAVES, 2002 apud CARVALHO, 2012).

c) Correlação de Pearson

$$Correl = \frac{\sum_1^n (V_{mod} - \overline{V_{mod}})(V_{obs} - \overline{V_{obs}})}{\sqrt{(n-1)\sigma_{mod}\sigma_{obs}}} \quad (11)$$

onde $\overline{V_{mod}}$ é a média dos valores modelados, $\overline{V_{obs}}$ é a média dos valores observados, σ_{mod} é o desvio padrão da velocidade modelada e σ_{obs} é o desvio padrão do valor observado.

A correlação indica o quanto os valores previstos estão relacionados linearmente. Assim, quanto mais próximo de zero, menor a correlação, isto é, menos as variáveis estão conexas. Analogamente, quanto mais próximo de +1 ou -1, mais forte é a correlação (positiva e negativa, respectivamente).

d) Erro percentual médio (EPM)

$$EPM = \frac{1}{n} \sum_1^n \frac{V_{mod} - V_{obs}}{|V_{obs}|} * 100 \quad (12)$$

O EPM expressa o erro relativo multiplicado por 100. O erro relativo é a razão entre o erro médio absoluto (EMA) e o valor observado/medido (KHOURY, 2011) pela estação anemométrica. Deste modo, quanto mais próximo de 0% maior a qualidade da previsão.

4 APRESENTAÇÃO DE RESULTADOS

4.1 ANÁLISE DOS DADOS

Após a realização da verificação dos dados válidos, conforme apresentado na seção 3.2, foram determinados todos os possíveis preditores de entrada no modelo (TABELA 3).

Para as variáveis que possuíam dados observados de minuto em minuto foram obtidas as médias a cada 10 minutos. Em seguida, o valor do dado horário utilizado na análise deste trabalho foi considerado como sendo a média de 10 minutos correspondente ao minuto zero, para todas as variáveis.

A precipitação foi excluída da análise por apresentar muitos dados faltantes e/ou inválidos. A inclusão desta variável iria diminuir o total de dados de forma significativa, podendo influenciar negativamente o resultado da previsão das velocidades do vento.

TABELA 3 – VARIÁVEIS SELECIONADAS COMO PREDITORAS APÓS A ETAPA DE VALIDAÇÃO DOS DADOS.

Variável	Sigla
Velocidade do vento a 25 metros	w25
Velocidade do vento a 50 metros	w50
Velocidade do vento a 10 metros	w10
Umidade Relativa	ur
Pressão Atmosférica	press
Radiação	rad
Temperatura a 25 metros	tp25
Temperatura a 50 metros	tp50
Temperatura na superfície	tps
Componente zonal da direção do vento a 25 metros	u25
Componente meridional da direção do vento a 25 metros	v25
Componente zonal da direção do vento a 50 metros	u50
Componente meridional da direção do vento a 50 metros	v50
Componente zonal da direção do vento a 10 metros	u10
Componente meridional da direção do vento a 10 metros	v10

4.2 CORRELAÇÕES

Nesta seção são apresentados os resultados referentes às correlações cruzadas. A TABELA 4 apresenta os possíveis preditores de entrada da rede, em que

foram realizadas análises de correlação cruzada da variável de saída (velocidade do vento a 25 metros) com os possíveis preditores, com até 30 horas de atraso. A TABELA 5 representa a correlação cruzada entre a velocidade do vento a 50 metros e os possíveis preditores, conforme mostrado na sequência.

TABELA 4 – CORRELAÇÕES CRUZADAS ENTRE A VELOCIDADE DO VENTO A 25 METROS E OS POSSÍVEIS PREDITORES, COM ATRASO DE ATÉ 30 HORAS.

<i>Variável/ Horas de atraso</i>	w25	w50	w10	u25	v25	u50	v50	u10	v10	ur	pres	rad	tp25	tps	tp50
1	0,74	0,69	0,70	-0,51	0,54	-0,51	0,46	-0,55	0,55	-0,27	0,39	0,11	0,01	0,08	-0,03
2	0,60	0,58	0,56	-0,43	0,50	-0,44	0,43	-0,45	0,50	-0,21	0,40	0,00	-0,05	0,01	-0,08
3	0,51	0,50	0,46	-0,36	0,47	-0,39	0,42	-0,38	0,46	-0,16	0,39	-0,06	-0,10	-0,05	-0,12
4	0,43	0,44	0,37	-0,31	0,43	-0,34	0,40	-0,32	0,41	-0,11	0,37	-0,10	-0,13	-0,10	-0,15
5	0,38	0,41	0,32	-0,28	0,41	-0,32	0,38	-0,28	0,38	-0,08	0,34	-0,12	-0,16	-0,13	-0,17
6	0,35	0,38	0,28	-0,27	0,39	-0,30	0,37	-0,26	0,36	-0,06	0,31	-0,14	-0,17	-0,15	-0,18
7	0,33	0,36	0,27	-0,26	0,37	-0,30	0,36	-0,25	0,35	-0,05	0,29	-0,14	-0,18	-0,15	-0,19
8	0,32	0,35	0,26	-0,26	0,37	-0,30	0,35	-0,25	0,35	-0,04	0,28	-0,11	-0,17	-0,15	-0,18
9	0,31	0,34	0,25	-0,25	0,36	-0,29	0,34	-0,24	0,33	-0,05	0,29	-0,05	-0,17	-0,15	-0,18
10	0,30	0,34	0,24	-0,25	0,34	-0,29	0,33	-0,24	0,32	-0,06	0,31	0,02	-0,16	-0,14	-0,16
11	0,30	0,35	0,23	-0,24	0,33	-0,29	0,33	-0,23	0,31	-0,07	0,32	0,11	-0,14	-0,13	-0,14
12	0,30	0,36	0,22	-0,24	0,33	-0,29	0,33	-0,22	0,29	-0,09	0,33	0,17	-0,12	-0,12	-0,12
13	0,30	0,36	0,21	-0,23	0,32	-0,28	0,32	-0,21	0,28	-0,11	0,33	0,17	-0,10	-0,11	-0,09
14	0,29	0,36	0,20	-0,22	0,31	-0,27	0,32	-0,19	0,27	-0,13	0,31	0,08	-0,07	-0,08	-0,06
15	0,29	0,35	0,20	-0,22	0,30	-0,27	0,31	-0,19	0,26	-0,16	0,28	-0,06	-0,03	-0,04	-0,02
16	0,29	0,34	0,22	-0,22	0,30	-0,26	0,30	-0,20	0,26	-0,20	0,24	-0,17	0,01	0,00	0,02
17	0,30	0,34	0,24	-0,23	0,30	-0,26	0,30	-0,22	0,28	-0,24	0,20	-0,19	0,06	0,05	0,05
18	0,31	0,33	0,26	-0,23	0,31	-0,26	0,30	-0,23	0,29	-0,28	0,17	-0,15	0,09	0,10	0,08
19	0,33	0,34	0,29	-0,25	0,32	-0,27	0,30	-0,25	0,31	-0,31	0,15	-0,04	0,12	0,14	0,11
20	0,36	0,35	0,33	-0,27	0,34	-0,28	0,30	-0,28	0,33	-0,33	0,16	0,09	0,14	0,16	0,12
21	0,40	0,38	0,38	-0,30	0,36	-0,31	0,31	-0,32	0,35	-0,34	0,19	0,19	0,14	0,18	0,12
22	0,45	0,42	0,44	-0,34	0,38	-0,34	0,32	-0,37	0,38	-0,34	0,24	0,25	0,13	0,18	0,11
23	0,50	0,46	0,49	-0,38	0,40	-0,38	0,33	-0,41	0,41	-0,32	0,29	0,24	0,10	0,16	0,08
24	0,53	0,48	0,52	-0,39	0,42	-0,39	0,34	-0,43	0,43	-0,29	0,33	0,19	0,06	0,12	0,03
25	0,49	0,45	0,48	-0,36	0,41	-0,36	0,34	-0,40	0,42	-0,23	0,36	0,09	0,00	0,06	-0,02
26	0,43	0,41	0,41	-0,32	0,39	-0,33	0,34	-0,34	0,40	-0,18	0,38	0,00	-0,05	0,00	-0,08
27	0,37	0,37	0,34	-0,27	0,37	-0,29	0,33	-0,29	0,36	-0,12	0,37	-0,06	-0,10	-0,06	-0,12
28	0,33	0,33	0,28	-0,24	0,34	-0,26	0,31	-0,24	0,33	-0,08	0,35	-0,09	-0,14	-0,11	-0,16
29	0,29	0,30	0,24	-0,22	0,32	-0,25	0,30	-0,22	0,31	-0,05	0,32	-0,12	-0,17	-0,14	-0,18
30	0,26	0,29	0,21	-0,21	0,31	-0,24	0,29	-0,20	0,29	-0,03	0,29	-0,13	-0,18	-0,16	-0,19

TABELA 5– CORRELAÇÕES CRUZADAS ENTRE A VELOCIDADE DO VENTO A 50 METROS E OS POSSÍVEIS PREDITORES, COM ATRASO DE ATÉ 30 HORAS.

<i>Variável / Horas de atraso</i>	w25	w50	w10	u25	v25	u50	v50	u10	v10	ur	pres	rad	tp25	tps	tp50
1	0,69	0,73	0,58	-0,44	0,56	-0,49	0,52	-0,44	0,54	-0,22	0,37	-0,01	-0,04	-0,01	-0,05
2	0,57	0,60	0,47	-0,37	0,51	-0,42	0,48	-0,36	0,49	-0,22	0,35	-0,12	-0,03	-0,01	-0,05
3	0,48	0,53	0,39	-0,32	0,48	-0,37	0,45	-0,31	0,45	-0,21	0,32	-0,17	-0,03	-0,02	-0,04
4	0,43	0,47	0,33	-0,28	0,44	-0,33	0,42	-0,27	0,41	-0,21	0,29	-0,17	-0,02	-0,01	-0,03
5	0,39	0,43	0,31	-0,26	0,42	-0,31	0,40	-0,25	0,39	-0,21	0,26	-0,14	-0,02	0,00	-0,02
6	0,37	0,40	0,30	-0,26	0,40	-0,30	0,38	-0,25	0,38	-0,21	0,24	-0,09	-0,01	0,01	-0,02
7	0,37	0,38	0,31	-0,27	0,39	-0,30	0,37	-0,27	0,37	-0,22	0,24	-0,04	0,00	0,02	-0,01
8	0,37	0,38	0,32	-0,28	0,39	-0,31	0,36	-0,29	0,38	-0,22	0,26	0,02	0,00	0,03	-0,02
9	0,37	0,37	0,33	-0,29	0,38	-0,31	0,35	-0,30	0,37	-0,21	0,28	0,08	-0,01	0,02	-0,03
10	0,36	0,36	0,33	-0,30	0,37	-0,32	0,34	-0,31	0,36	-0,20	0,32	0,12	-0,02	0,01	-0,04
11	0,37	0,37	0,34	-0,30	0,37	-0,32	0,33	-0,31	0,36	-0,18	0,35	0,15	-0,05	-0,01	-0,06
12	0,36	0,37	0,32	-0,29	0,36	-0,31	0,33	-0,30	0,35	-0,16	0,38	0,17	-0,07	-0,03	-0,08
13	0,35	0,37	0,30	-0,28	0,35	-0,30	0,33	-0,29	0,33	-0,13	0,39	0,15	-0,09	-0,06	-0,10
14	0,33	0,36	0,28	-0,26	0,35	-0,29	0,33	-0,26	0,32	-0,12	0,38	0,11	-0,11	-0,08	-0,12
15	0,32	0,35	0,26	-0,26	0,34	-0,29	0,33	-0,26	0,31	-0,11	0,36	-0,01	-0,11	-0,09	-0,12
16	0,32	0,35	0,27	-0,26	0,34	-0,29	0,33	-0,26	0,32	-0,11	0,34	-0,10	-0,11	-0,09	-0,12
17	0,33	0,35	0,28	-0,26	0,35	-0,29	0,33	-0,26	0,33	-0,12	0,31	-0,15	-0,10	-0,08	-0,11
18	0,34	0,36	0,29	-0,26	0,36	-0,29	0,34	-0,27	0,34	-0,13	0,29	-0,13	-0,09	-0,06	-0,10
19	0,35	0,37	0,30	-0,27	0,37	-0,30	0,35	-0,27	0,35	-0,14	0,27	-0,06	-0,07	-0,05	-0,09
20	0,37	0,39	0,31	-0,28	0,38	-0,31	0,36	-0,28	0,36	-0,16	0,28	0,03	-0,06	-0,03	-0,07
21	0,39	0,42	0,34	-0,29	0,39	-0,33	0,37	-0,29	0,38	-0,17	0,29	0,10	-0,05	-0,02	-0,06
22	0,42	0,45	0,36	-0,31	0,41	-0,35	0,38	-0,31	0,39	-0,19	0,31	0,14	-0,04	-0,01	-0,05
23	0,45	0,48	0,39	-0,32	0,42	-0,36	0,39	-0,33	0,40	-0,19	0,33	0,13	-0,03	-0,01	-0,05
24	0,47	0,50	0,40	-0,33	0,43	-0,37	0,39	-0,33	0,40	-0,20	0,34	0,08	-0,03	-0,01	-0,04
25	0,44	0,47	0,37	-0,30	0,42	-0,34	0,39	-0,30	0,40	-0,19	0,34	-0,02	-0,04	-0,02	-0,04
26	0,39	0,42	0,32	-0,26	0,40	-0,30	0,37	-0,26	0,38	-0,18	0,33	-0,12	-0,04	-0,03	-0,05
27	0,35	0,38	0,27	-0,23	0,37	-0,27	0,35	-0,22	0,35	-0,17	0,30	-0,17	-0,04	-0,03	-0,04
28	0,31	0,35	0,24	-0,21	0,35	-0,25	0,33	-0,20	0,33	-0,17	0,27	-0,16	-0,03	-0,03	-0,04
29	0,29	0,32	0,22	-0,19	0,33	-0,23	0,31	-0,19	0,31	-0,18	0,25	-0,13	-0,03	-0,02	-0,03
30	0,28	0,30	0,22	-0,20	0,31	-0,23	0,30	-0,19	0,30	-0,18	0,23	-0,09	-0,02	0,00	-0,02

Para este estudo, arbitrou-se subjetivamente que seriam consideradas as variáveis que possuísem correlação maior ou igual a 0,4 com a variável de interesse (indicadas em negrito nas tabelas).

Pode-se observar na TABELA 4 e na TABELA 5 que alguns componentes da direção do vento também apresentaram correlação linear superior a 0,4, mas que não foram selecionados como preditores. Isso é justificado pelo fato de as componentes da direção do vento refletirem a velocidade do vento. Desta forma, nota-se que, para os atrasos horários das velocidades selecionadas como potenciais preditores, os componentes da direção do vento apresentaram correlações inferiores às correlações apresentadas pelas variáveis de velocidade. Assim, a fim de simplificar o problema e reduzir o tempo de processamento da rede RBF, a direção do vento foi excluída da análise por possuir dados considerados redundantes, já que a própria velocidade do vento foi inclusa na análise.

É importante destacar que o valor de correlação linear de 0,4 foi atribuído subjetivamente após observar as correlações resultantes. Para a previsão da velocidade do vento a 25 metros foram selecionadas 29 variáveis e para a previsão da velocidade do vento 50 metros foram 23. Considerando o tempo de processamento de cada simulação, esse número de variáveis selecionadas já é elevado, como será visto na seção 4.3. Sendo assim, não foi considerado adequado eleger variáveis com correlações cruzadas inferiores a 0,4.

Verifica-se que em ambas as configurações (25 e 50 metros) as próprias velocidades do vento são mais importantes que as demais variáveis para a previsão. Observa-se que, para radiação; temperatura de superfície; temperatura a 25 metros e temperatura a 50 metros, as correlações são muito baixas, não ultrapassando o valor de 0,19. A umidade relativa também resultou em uma baixa correlação com as variáveis de interesse, atingindo uma correlação máxima de -0,34 com a velocidade a 25 metros e 0,22 com a velocidade a 50 metros. Portanto, constatou-se que essas variáveis não são significativas para a previsão da velocidade do vento quando comparadas às demais variáveis.

4.3 SELEÇÃO DOS PREDITORES ÓTIMOS

Para a seleção dos preditores ótimos, isto é, os preditores que foram efetivamente utilizados na camada de entrada da rede neural artificial RBF, utilizou-

se o método *stepwise* (vide seção 3.3.2) com os preditores selecionados a partir da correlação com a variável de interesse (seção 4.2).

4.3.1 Seleção de variáveis de entrada para a previsão da velocidade do vento a 25 metros

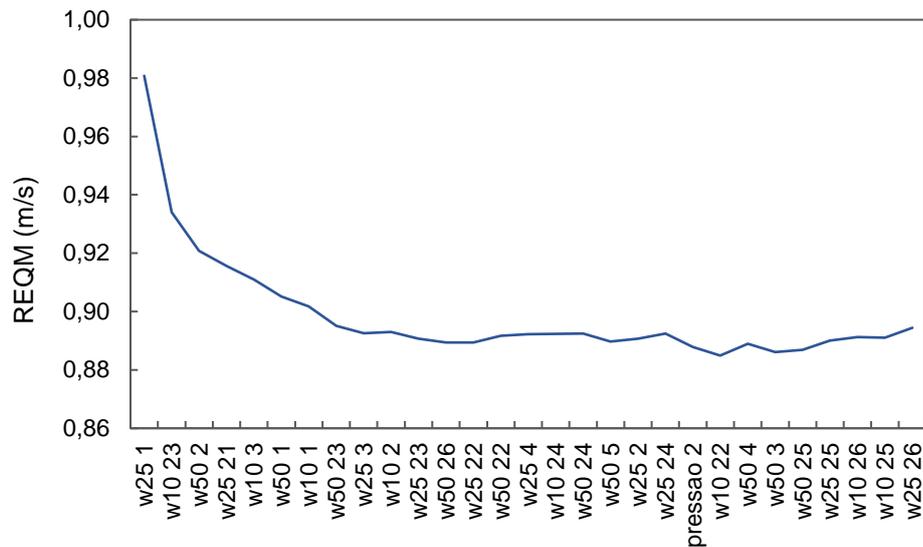
A implementação do método empregou a raiz do erro quadrático médio (REQM) como métrica estatística de referência. Conforme os preditores são adicionados, o erro tende a diminuir, porém em um certo momento começa a ocorrer uma oscilação do erro em torno de um determinado valor e, eventualmente, o erro passa a aumentar, assim como pode ser visualizado na FIGURA 24.

Para cada experimento de previsão foram realizados 3 testes do método de regressão utilizado as mesmas configurações, a fim de se determinar com maior acurácia as variáveis ótimas para entrada do modelo. Essas variáveis foram escolhidas observando os gráficos de erros e a frequência de relevância dentre os testes, de modo que esses preditores contribuíssem para uma melhor previsão da velocidade do vento (quanto menor o erro melhor a previsibilidade) e uma redução do tempo de processamento da rede neural.

Pelos gráficos, foram desconsideradas as variáveis que estavam localizadas a partir do ponto em que foi interpretado que o erro (REQM) estabilizou ou aumentou, não sendo consideradas relevantes para a previsão da velocidade do vento. Como foram feitos 3 ciclos de testes, essa análise foi feita para todos os 3 ciclos e as variáveis que foram descartadas tiveram frequência de relevância inferior a 2, isto é, estavam localizadas além do ponto que o erro estabiliza/aumenta no gráfico em pelo menos dois dos três ciclos de testes.

Os demais resultados do método *stepwise* para a identificação dos preditores ótimos dos modelos em todos os horizontes de previsão são apresentados no APÊNDICE 1 — RESULTADOS DO MÉTODO DE REGRESSÃO.

FIGURA 24 – EXEMPLO DE UM CICLO REALIZADO PELO MÉTODO DE REGRESSÃO *STEPWISE* PARA A VELOCIDADE DO VENTO A 25 METROS.



As siglas dadas para cada variável já foram apresentadas anteriormente. Na FIGURA 24, no eixo das abcissas, os números após a sigla são referentes às horas de atraso.

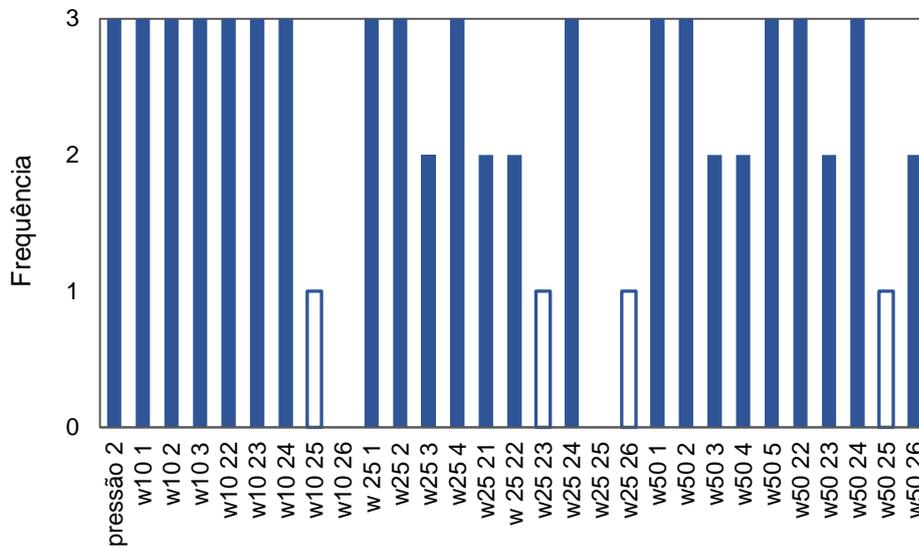
Para cada uma das configurações, fez-se, ainda, testes com diferentes números de neurônios na camada oculta. Foram testados 10, 20, 30, 40 e 50 neurônios, em que cada horizonte de previsão obteve diferentes configurações, como será visto mais adiante neste documento.

Não foi possível realizar análises com números de neurônios superiores a 50, uma vez que o tempo de processamento chegou a 29 horas para os horizontes com maior número de variáveis e esse tempo aumenta conforme os neurônios na camada oculta também aumentam.

4.3.1.1 Horizonte de previsão de 1 hora

Para a previsão 1 hora à frente, a melhor configuração encontrada foi a com 20 neurônios na camada oculta. A FIGURA 25 apresenta o resultado dos três testes do método de regressão *stepwise*. Nota-se que 16 variáveis se mostraram significativas em todos os ciclos de testes. Do mesmo modo, outras 7 variáveis auxiliaram na redução da REQM e foram consideradas importantes para o modelo em 2 dos ciclos de testes. Assim, selecionaram-se 23 preditores ótimos (variáveis indicadas com as barras preenchidas com azul). Essa etapa obteve o maior tempo de processamento, correspondente a 29 horas.

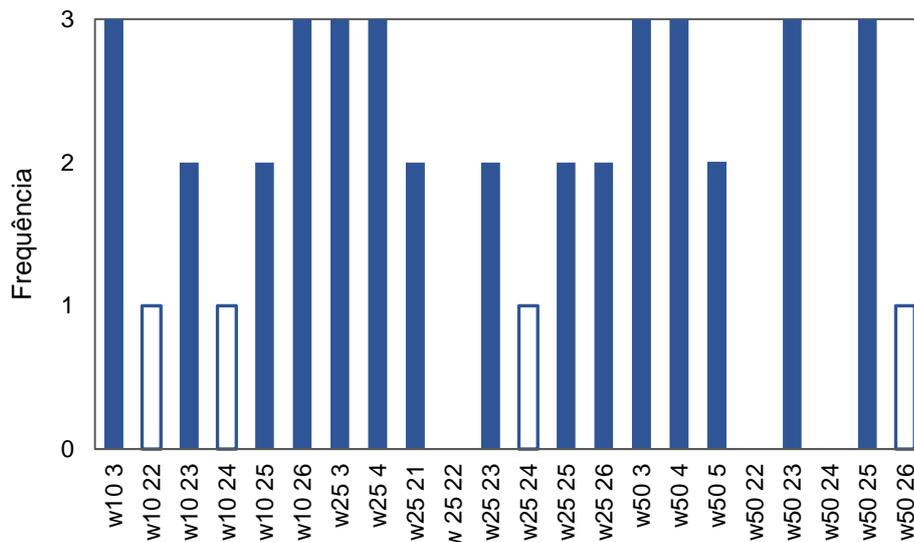
FIGURA 25 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 1 HORA À FRENTE DA VELOCIDADE DO VENTO A 25 METROS.



4.3.1.2 Horizonte de previsão de 3 horas

Para a previsão de 3 horas à frente, a melhor configuração encontrada também foi a com 20 neurônios na camada oculta. Na FIGURA 26 vê-se que 8 variáveis foram relevantes em todos os ciclos de testes. Ao todo, 15 preditores ótimos foram escolhidos.

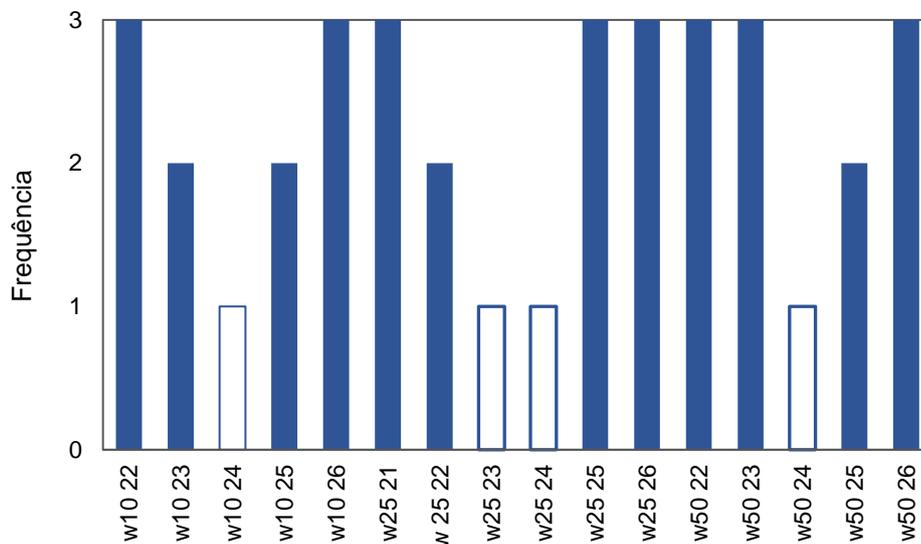
FIGURA 26 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 3 HORAS À FRENTE DA VELOCIDADE DO VENTO A 25 METROS.



4.3.1.3 Horizonte de previsão de 6 horas

Para a previsão de 6 horas adiante, escolheu-se a configuração com 30 neurônios na camada oculta. Em relação às variáveis selecionadas como entrada no modelo da RNA RBF é possível observar na FIGURA 27 que 8 variáveis apareceram em todos os ciclos de testes e 4 apareceram em dois dos ciclos e foram consideradas relevantes. No total, selecionou-se 12 variáveis.

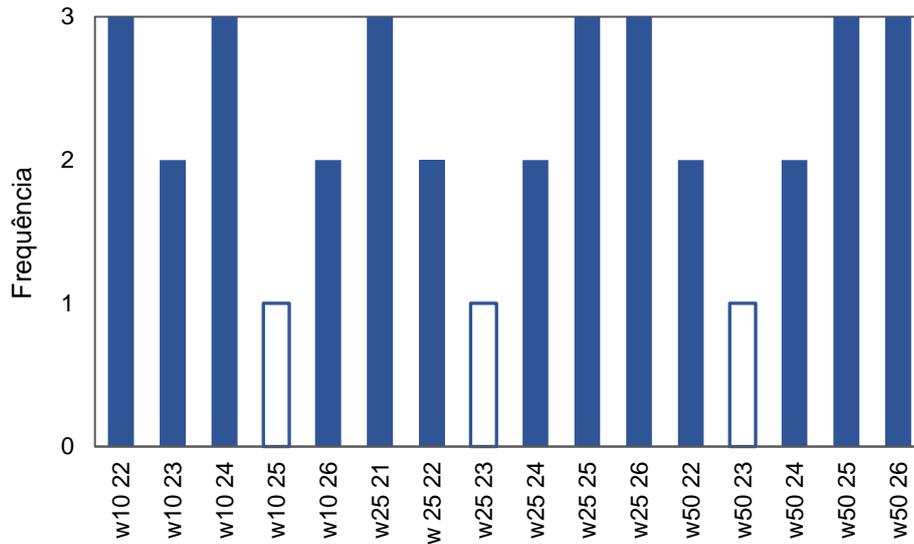
FIGURA 27 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 6 HORAS À FRENTE DA VELOCIDADE DO VENTO A 25 METROS.



4.3.1.4 Horizonte de previsão de 12 horas

Para a previsão de 12 horas à frente foi escolhida a configuração com 15 neurônios na camada oculta. Ao todo foram escolhidas 13 variáveis, 7 das quais apareceram em todos os ciclos (FIGURA 28).

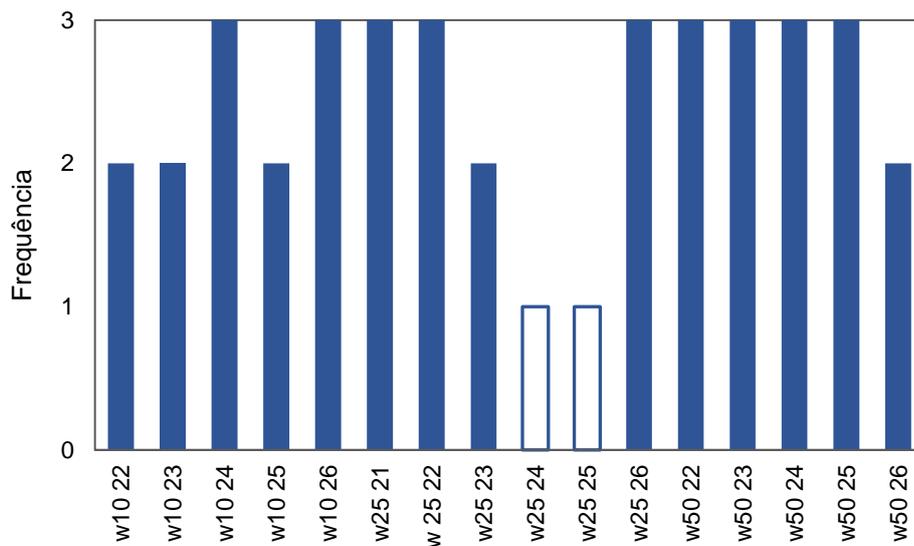
FIGURA 28 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 12 HORAS À FRENTE DA VELOCIDADE DO VENTO A 25 METROS.



4.3.1.5 Horizonte de previsão de 18 horas

Para o horizonte de previsão de 18 horas, 9 dos 16 preditores mostraram-se relevantes nos três ciclos. Para essa configuração foram consideradas 14 variáveis como significativas para o modelo de previsão da velocidade do vento (FIGURA 29). Foram utilizados 15 neurônios na camada oculta.

FIGURA 29 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 18 HORAS À FRENTE DA VELOCIDADE DO VENTO A 25 METROS.

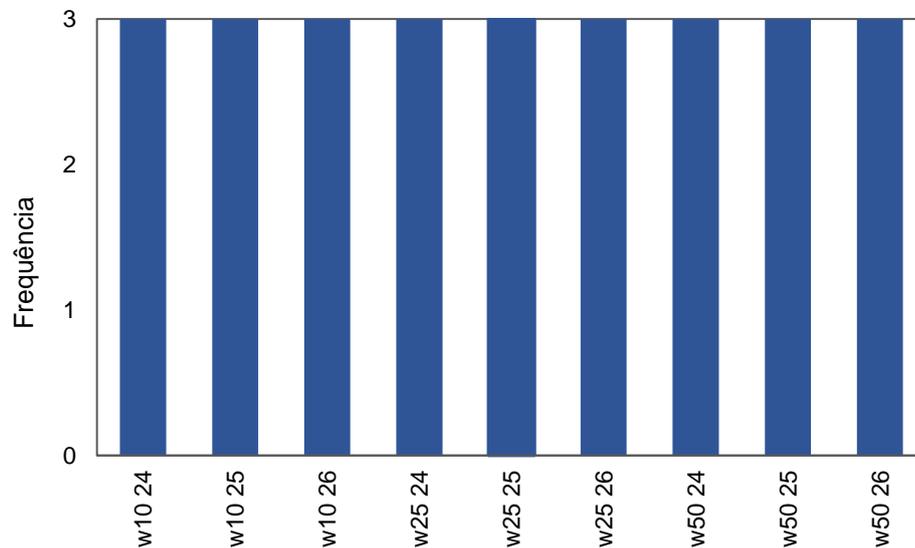


4.3.1.6 Horizonte de previsão de 24 horas

Para prever a velocidade do vento um dia à frente, escolheu-se a configuração com 20 neurônios na camada oculta. Em relação às variáveis selecionadas como entrada no modelo da RNA RBF todas as 9 preditoras foram consideradas relevantes para a previsão da velocidade do vento a 25 metros (FIGURA 30).

Para esta configuração, o tempo de processamento foi de, aproximadamente, 6 horas.

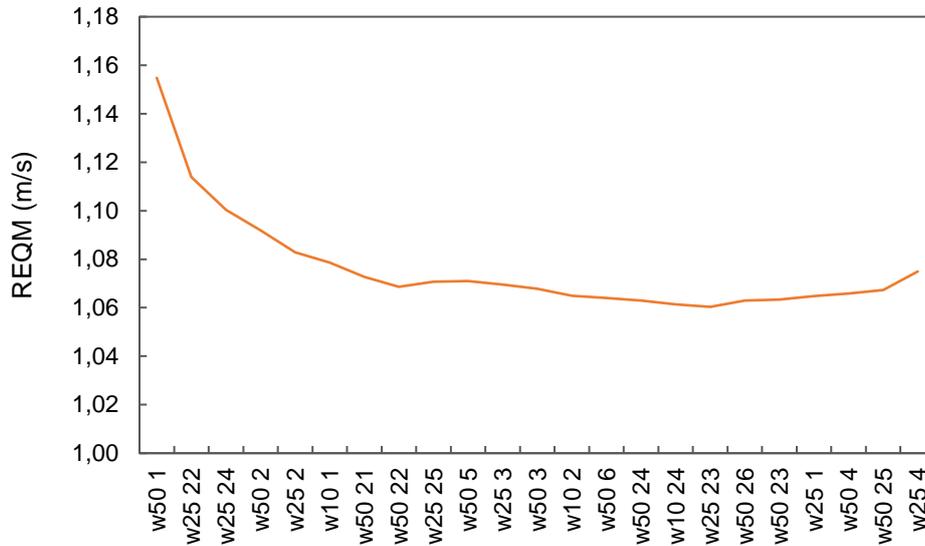
FIGURA 30 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 24 HORAS À FRENTE DA VELOCIDADE DO VENTO A 25 METROS.



4.3.2 Seleção de variáveis de entrada para a previsão da velocidade do vento a 50 metros

Considerando a variável de saída como a velocidade do vento a 50 metros, o método de regressão *stepwise* teve um tempo de processamento de cerca de 25 horas para os horizontes com maior número de variáveis. Um exemplo do resultado de um dos ciclos deste método é a FIGURA 31. O restante dos resultados é mostrado no APÊNDICE 1 — RESULTADOS DO MÉTODO DE REGRESSÃO.

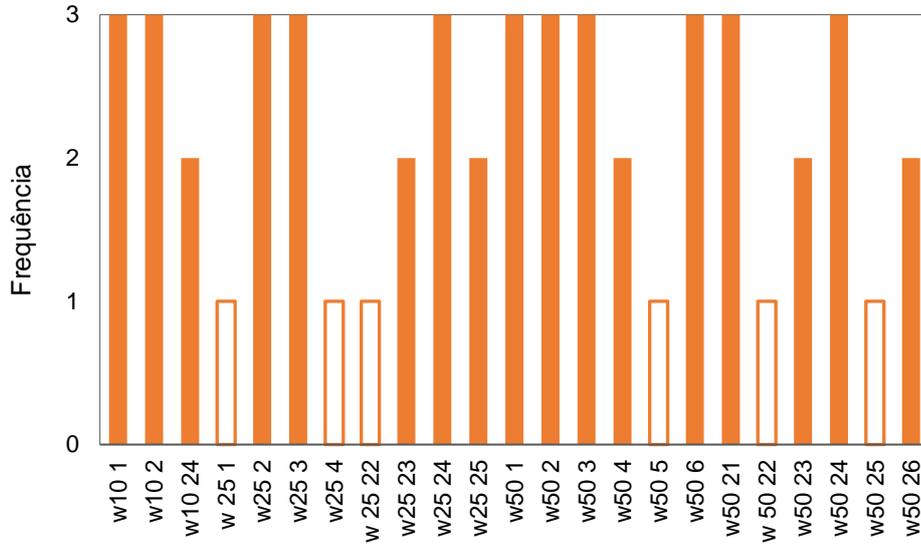
FIGURA 31 – EXEMPLO DE UM CICLO REALIZADO PELO MÉTODO DE REGRESSÃO *STEPWISE* PARA A VELOCIDADE DO VENTO A 50 METROS.



4.3.2.1 Horizonte de previsão de 1 hora

Para a previsão 1 hora à frente, a melhor configuração encontrada foi a com 30 neurônios na camada oculta. A FIGURA 32 apresenta o resultado dos três testes do método de regressão *stepwise*. 11 variáveis se mostraram significativas em todos os ciclos de testes. Do mesmo modo, outras 6 variáveis foram consideradas importantes para o modelo em 2 dos ciclos de testes. Ao todo, selecionaram-se 17 preditores ótimos (variáveis indicadas com as barras preenchidas com a cor laranja). O tempo de processamento para este horizonte de previsão foi de 25 horas.

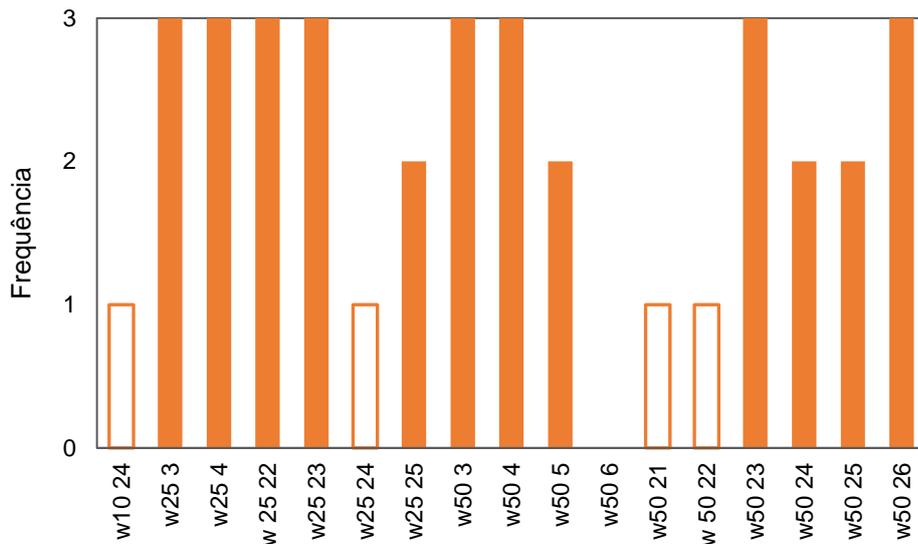
FIGURA 32 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 1 HORA À FRENTE DA VELOCIDADE DO VENTO A 50 METROS.



4.3.2.2 Horizonte de previsão de 3 horas

Para a previsão de 3 horas à frente, o número ótimo de neurônios na camada oculta foi de 40. A FIGURA 33 apresenta o resultado dos três testes do método de regressão *stepwise*. 12 preditores foram escolhidos, em que 8 deles se repetiram em todos os ciclos.

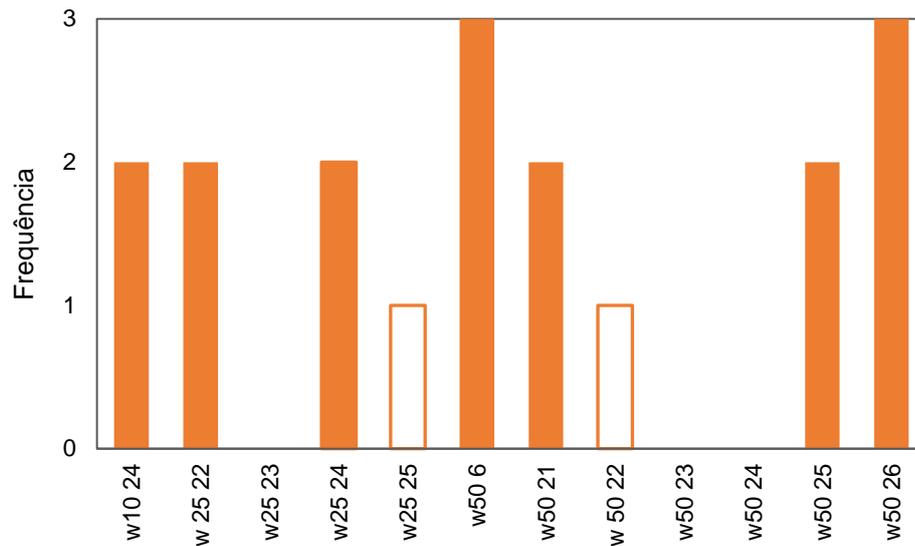
FIGURA 33 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 3 HORAS À FRENTE DA VELOCIDADE DO VENTO A 50 METROS.



4.3.2.3 Horizonte de previsão de 6 horas

Para prever 6 horas à frente, escolheu-se a configuração com 15 neurônios na camada oculta. Em relação às variáveis selecionadas como entrada no modelo da RNA RBF, 7 foram consideradas relevantes para a previsão da velocidade do vento a 50 metros, em que apenas 2 apareceram em todos os 3 testes (FIGURA 34).

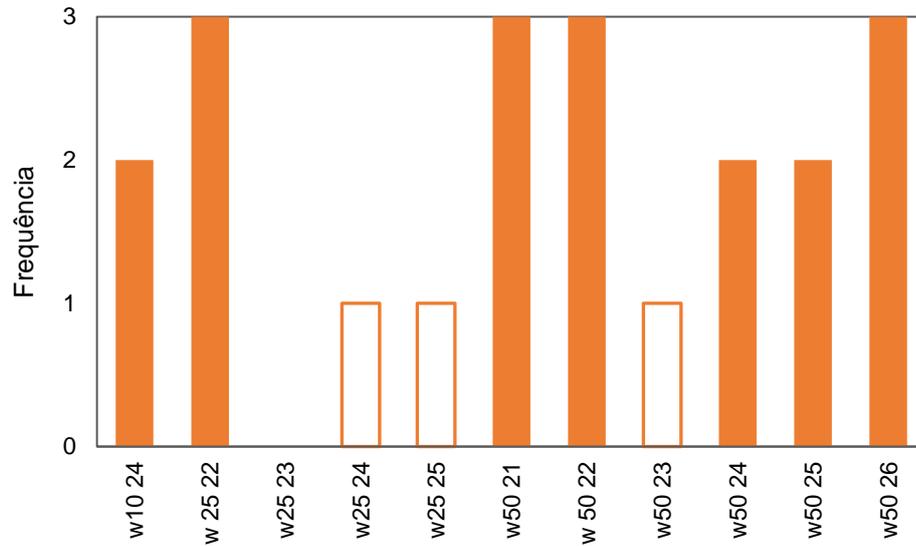
FIGURA 34 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 6 HORAS À FRENTE DA VELOCIDADE DO VENTO A 50 METROS.



4.3.2.4 Horizonte de previsão de 12 horas

Para um horizonte de previsão de 12 horas, a melhor configuração foi com 50 neurônios na camada oculta. Para este experimento, 7 das 11 preditoras foram consideradas significativas, assim como pode ser visualizado na FIGURA 35.

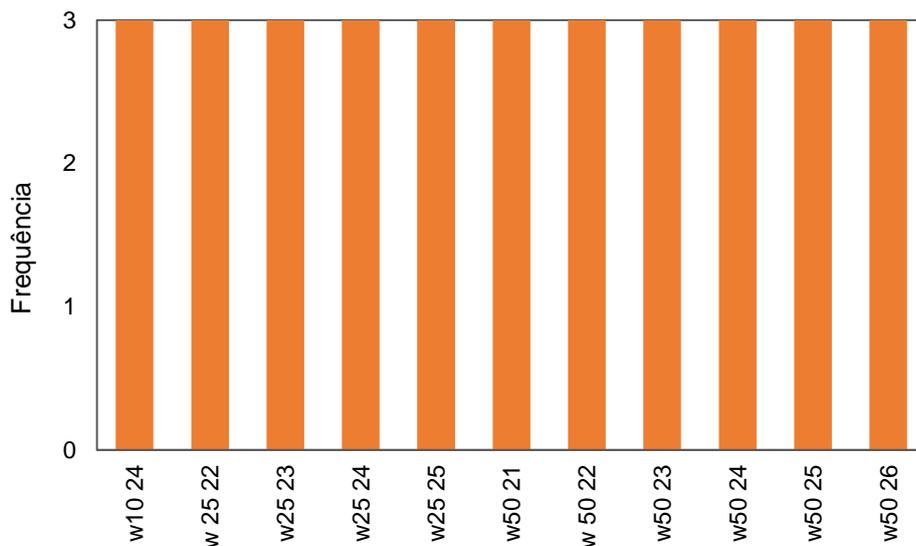
FIGURA 35 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 12 HORAS À FRENTE DA VELOCIDADE DO VENTO A 50 METROS.



4.3.2.5 Horizonte de previsão de 18 horas

Já para prever 18 horas à frente, a configuração com 20 neurônios na camada oculta foi a que resultou em um menor erro REQM. Todos os preditores foram considerados preditores ótimos e, assim, as 11 variáveis foram escolhidas como dados de entrada da rede neural RBF (FIGURA 36).

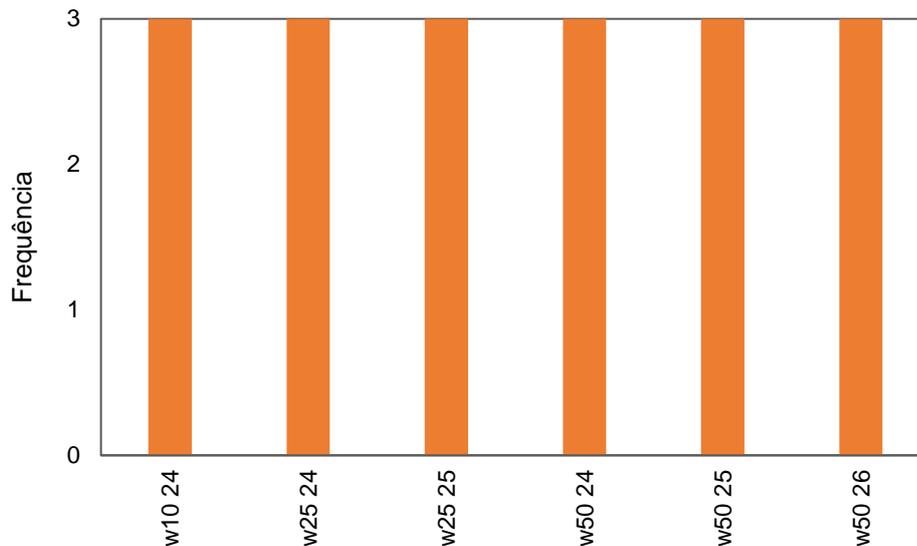
FIGURA 36 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 18 HORAS À FRENTE DA VELOCIDADE DO VENTO A 50 METROS.



4.3.2.6 Horizonte de previsão de 24 horas

Para prever um dia à frente, escolheu-se a configuração com 50 neurônios na camada oculta. Do mesmo modo que o horizonte de previsão de 18 horas, todos os preditores foram selecionados como ótimos (FIGURA 37). O tempo de processamento deste horizonte foi de, aproximadamente, 4 horas.

FIGURA 37 – FREQUÊNCIA DOS PREDITORES NOS 3 CICLOS DO MÉTODO DE REGRESSÃO PARA A PREVISÃO 24 HORAS À FRENTE DA VELOCIDADE DO VENTO A 50 METROS.



4.4 VERIFICAÇÃO DO DESEMPENHO DA REDE NEURAL RBF

Com as variáveis de entrada já definidas, realizaram-se as etapas de treinamento, teste e validação da rede neural. Na TABELA 6 e na TABELA 7 são apresentados os números de neurônios utilizados em cada camada da rede neural para cada previsão simulada. Relembra-se que as camadas de saída são referentes às velocidades do vento a 25 e 50 metros.

TABELA 6 – CONFIGURAÇÃO DO NÚMERO DE NEURÔNIOS DE CADA HORIZONTE DE PREVISÃO NA RNA RBF PARA A PREVISÃO DA VELOCIDADE DO VENTO A 25 METROS.

	1 hora	3 horas	6 horas	12 horas	18 horas	24 horas
Camada de entrada	23	15	12	13	14	9
Camada oculta	20	20	30	15	15	20
Camada de saída	1	1	1	1	1	1

TABELA 7 – CONFIGURAÇÃO DO NÚMERO DE NEURÔNIOS DE CADA HORIZONTE DE PREVISÃO NA RNA RBF PARA A PREVISÃO DA VELOCIDADE DO VENTO A 50 METROS.

	1 hora	3 horas	6 horas	12 horas	18 horas	24 horas
Camada de entrada	17	12	7	7	11	6
Camada oculta	30	40	15	50	20	50
Camada de saída	1	1	1	1	1	1

4.4.1 Previsão da velocidade do vento a 25 metros

As comparações entre os dados observados e os dados modelados pela RNA RBF para a previsão da velocidade do vento a 25 metros do nível do solo podem ser visualizadas nas FIGURA 38 a FIGURA 43.

FIGURA 38 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 1 HORA ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.

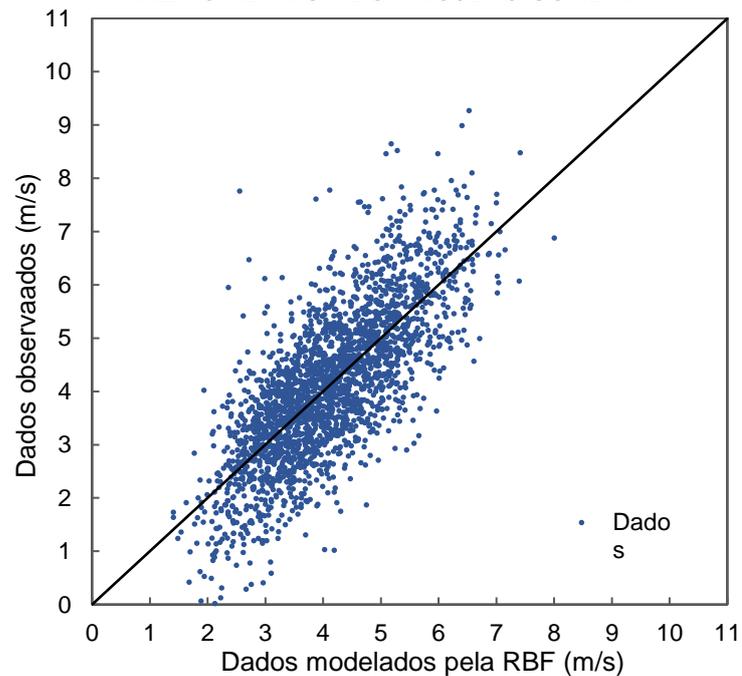


FIGURA 39 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 3 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.

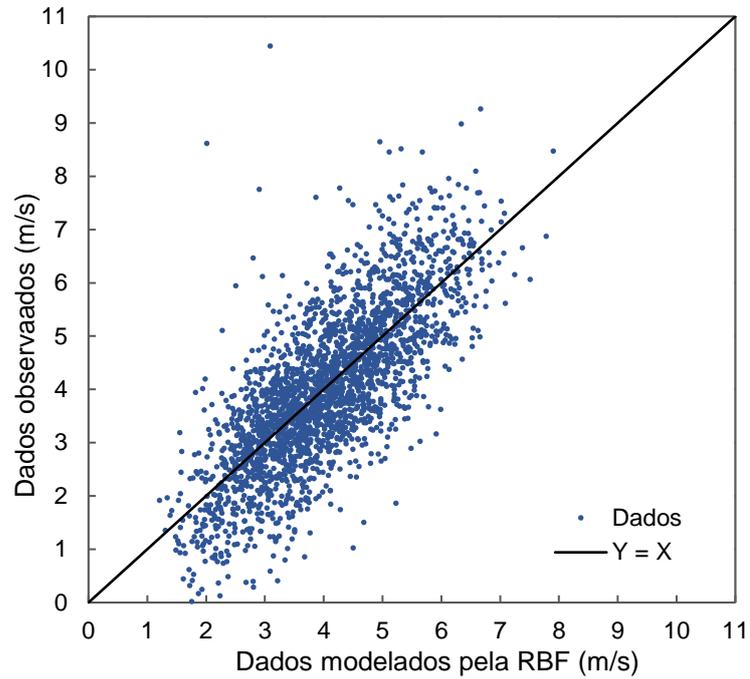


FIGURA 40 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 6 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.

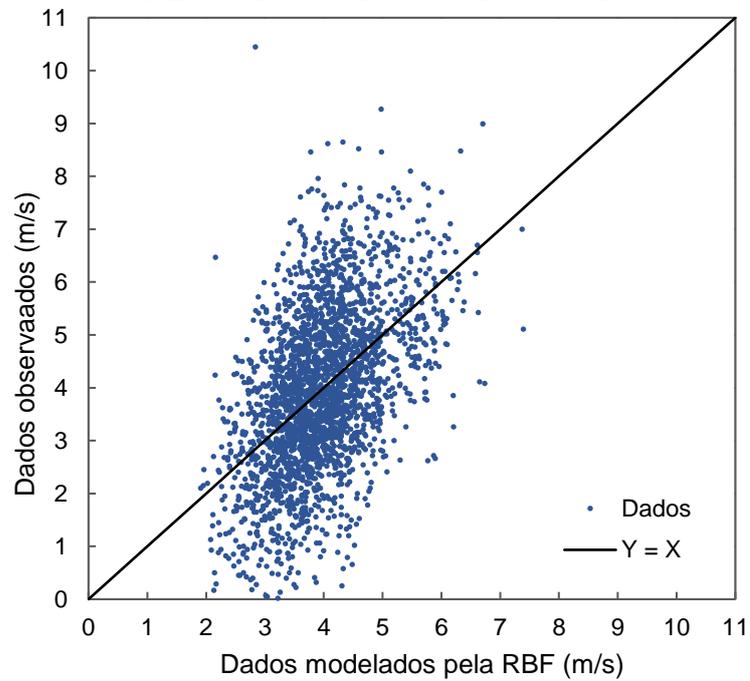


FIGURA 41 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 12 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.

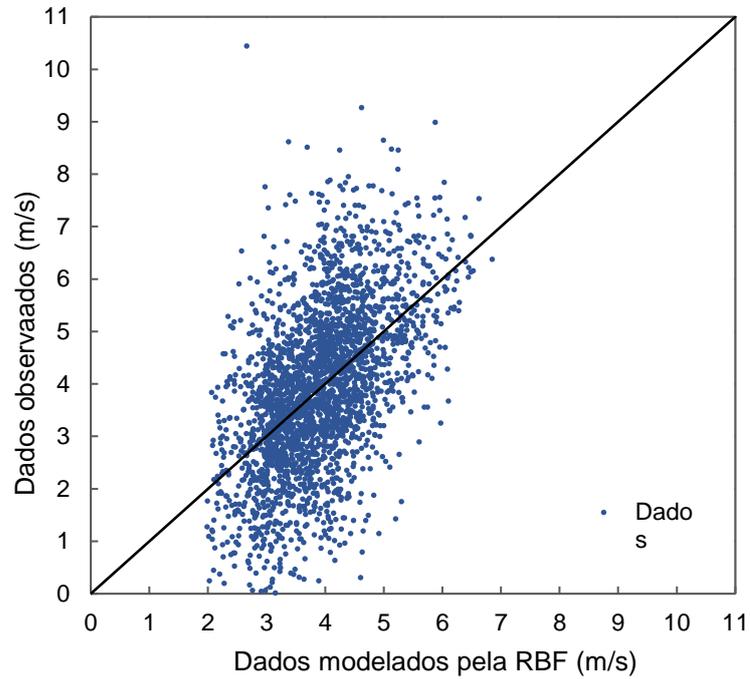


FIGURA 42 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 18 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.

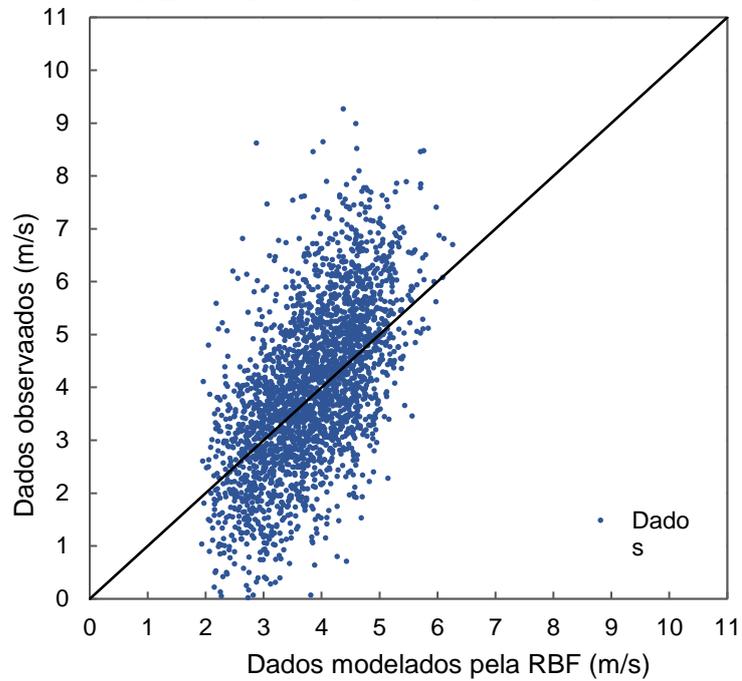
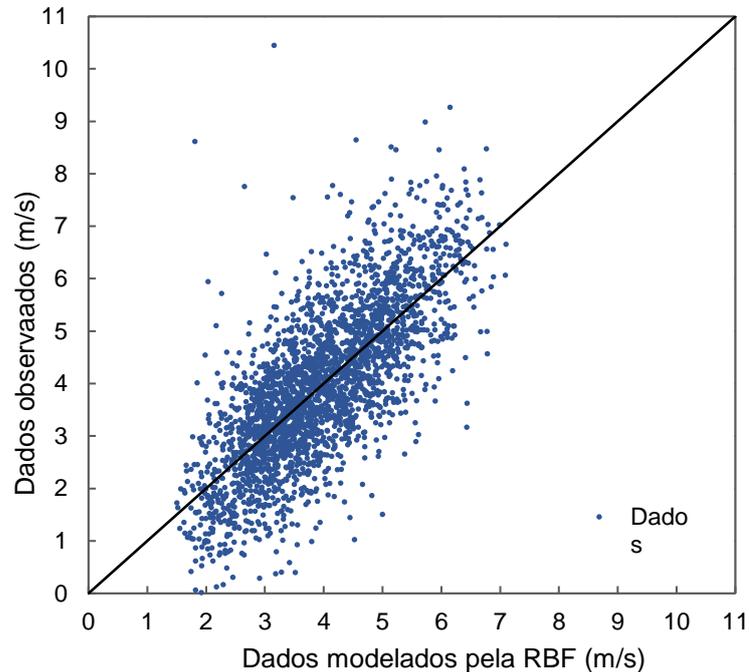


FIGURA 43 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 24 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.



Na TABELA 8 são apresentadas as métricas do desempenho da previsão da velocidade do vento a 25 metros utilizando a rede neural artificial RBF para cada horizonte de tempo previsto.

TABELA 8 – DESEMPENHO DA RNA RBF NA PREVISÃO DA VELOCIDADE DO VENTO A 25 METROS.

	1 hora	3 horas	6 horas	12 horas	18 horas	24 horas
Raiz do erro quadrático médio (m/s)	0,919	0,950	1,302	1,301	1,216	0,990
Erro médio absoluto (m/s)	0,712	0,723	1,028	1,008	0,951	0,755
Erro percentual (%)	-13,770	-13,850	-31,490	-32,120	-23,260	-14,900
Correlação de Pearson	0,750	0,750	0,490	0,520	0,590	0,740

4.4.2 Previsão da velocidade do vento a 50 metros

Do mesmo modo que foi feito para a altura de 25 metros, seguem-se as comparações (FIGURA 44 a FIGURA 49) entre os dados observados e os dados

modelados pela RNA RBF para a previsão da velocidade do vento a 50 metros do nível do solo.

FIGURA 44 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 1 HORA ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.

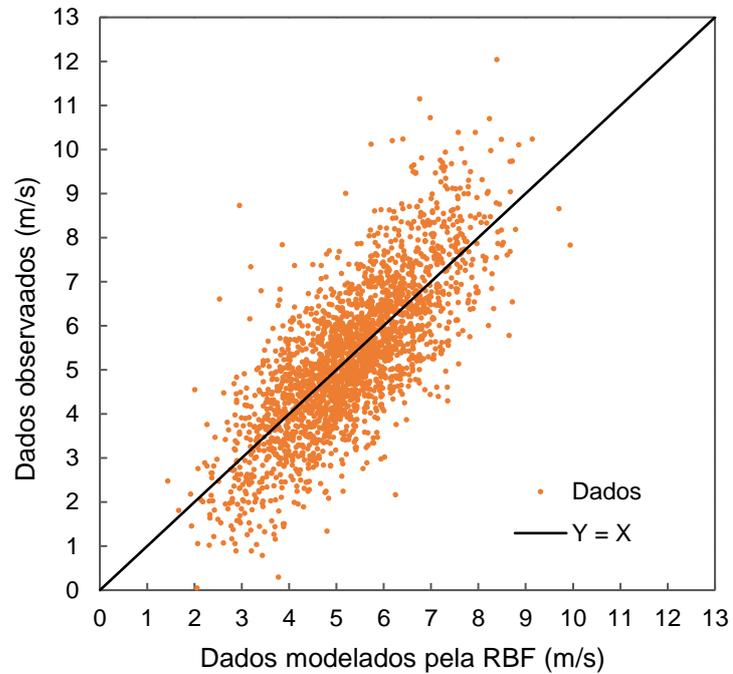


FIGURA 45 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 3 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.

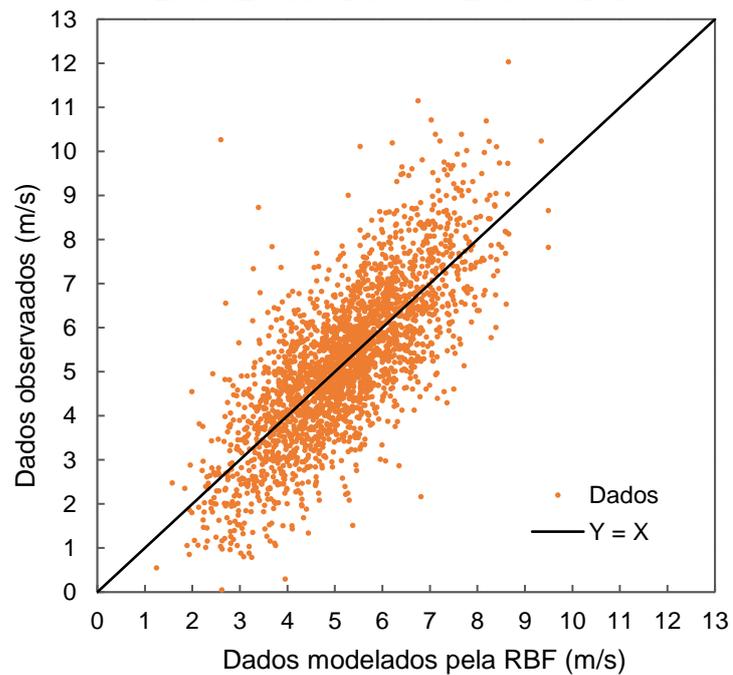


FIGURA 46 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 6 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.

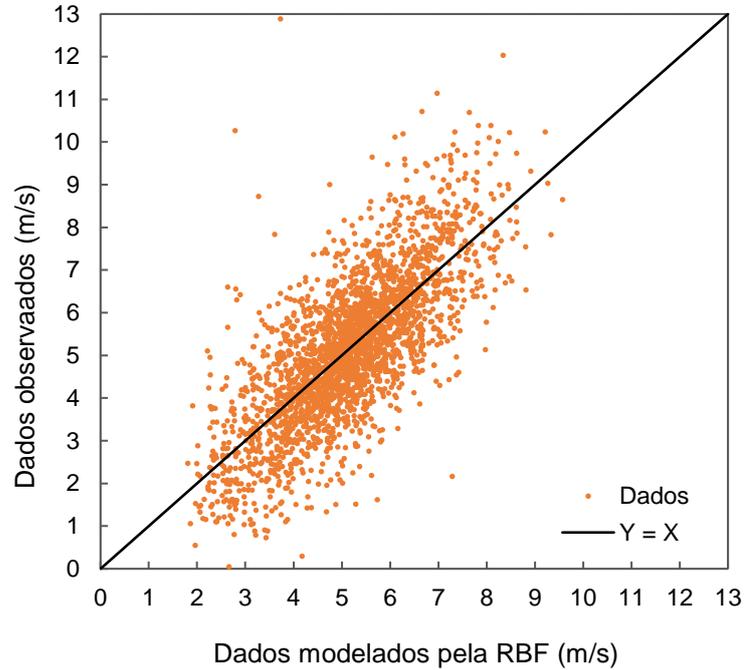


FIGURA 47 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 12 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.

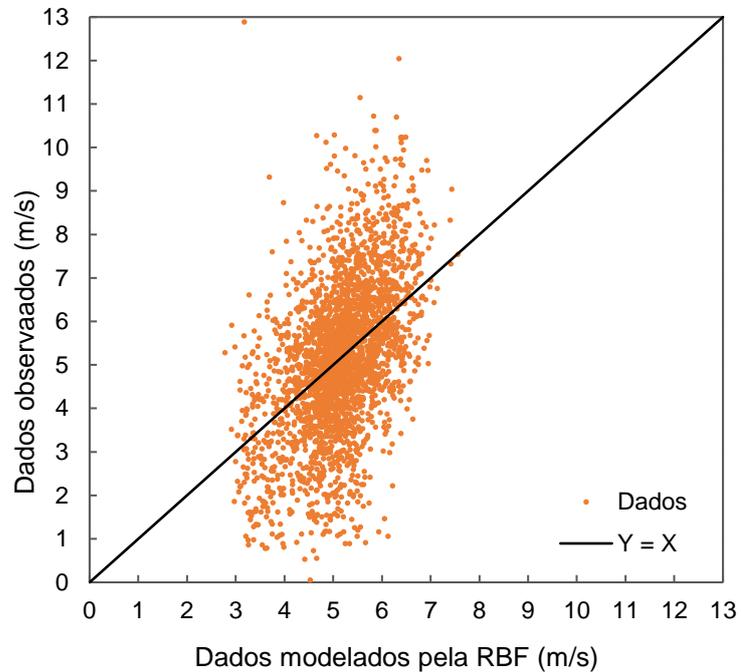


FIGURA 48 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 18 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.

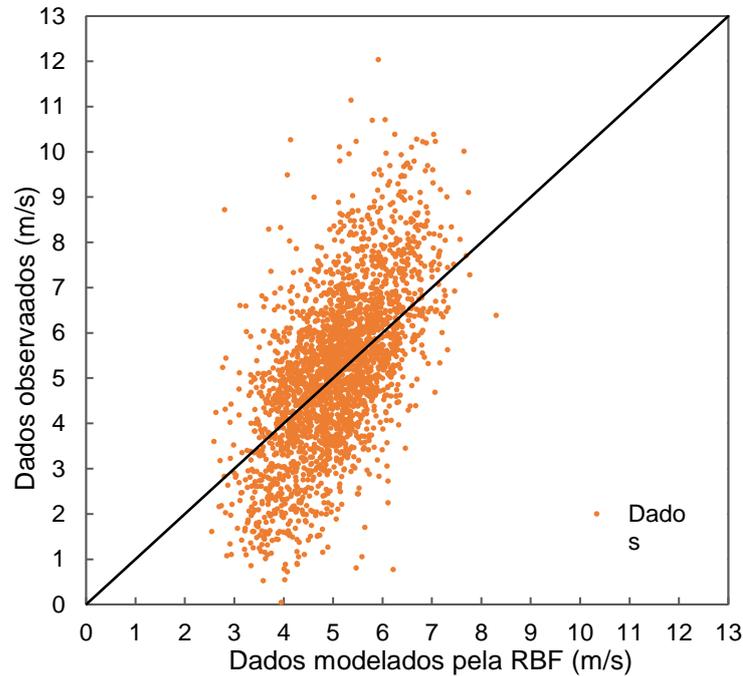
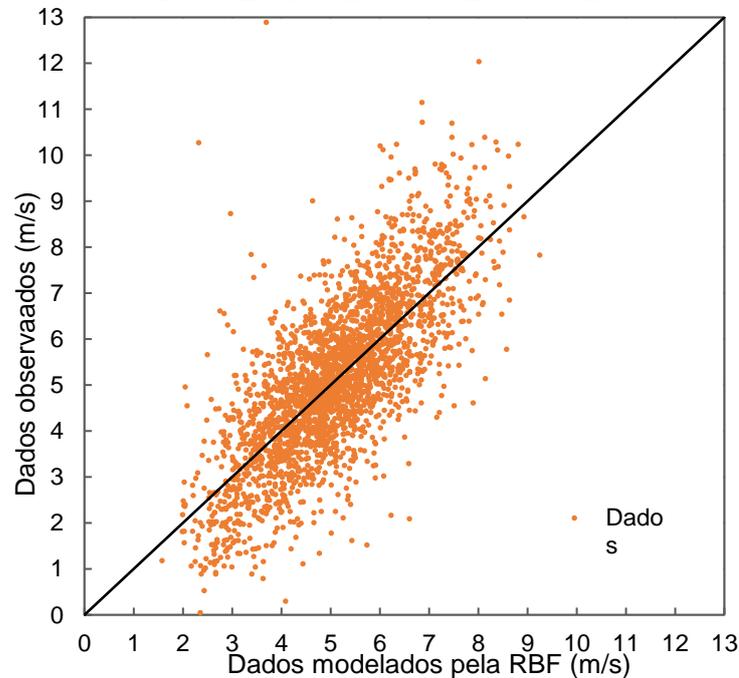


FIGURA 49 – GRÁFICO DE DISPERSÃO COM HORIZONTE DE PREVISÃO DE 24 HORAS ENTRE OS DADOS MODELADOS PELA RNA RBF E OS DADOS OBSERVADOS/MEDIDOS PELA TORRE ANEMOMÉTRICA DO PROJETO SONDA.



O desempenho da RNA na previsão da velocidade do vento a 50 metros para cada horizonte de tempo é apresentado na TABELA 9.

TABELA 9 – DESEMPENHO DA RNA RBF NA PREVISÃO DA VELOCIDADE DO VENTO A 50 METROS.

	1 hora	3 horas	6 horas	12 horas	18 horas	24 horas
Raiz do erro quadrático médio (m/s)	1,083	1,110	1,156	1,541	1,393	1,155
Erro médio absoluto (m/s)	0,847	0,859	0,881	1,192	1,082	0,879
Erro percentual (%)	-7,550	-8,200	-9,430	-18,170	-12,510	-8,260
Correlação	0,750	0,750	0,740	0,490	0,610	0,740

4.5 DISCUSSÃO DOS RESULTADOS

É possível notar pelos resultados apresentados anteriormente que a RNA RBF obteve os menores erros para a previsão da velocidade do vento em 25 metros de altura em relação ao nível do solo do que para 50 metros, para todos os horizontes de previsão, com exceção de 6 horas à frente.

Pelos gráficos de dispersão (FIGURA 38 a FIGURA 43) observa-se que a previsão 1 hora à frente foi a que apresentou melhores resultados, em que os pontos do gráfico estão mais próximos da reta que expressa a solução exata $y = x$. As previsões para 6, 12 e 18 horas à frente tiveram os resultados um pouco menos acurados, pois alguns pontos ficaram mais dispersos, indicando que as previsões nesses casos tiveram erros estatísticos maiores em relação aos outros horizontes de tempo. No horizonte de previsão de 24 horas à frente o cenário voltou a ficar semelhante aos menores horizontes de tempo (1 e 3 horas à frente), com um melhor resultado da previsão da velocidade do vento em uma altura de 25 metros.

Para a altura de 50 metros (FIGURA 44 a FIGURA 49) obteve-se comportamento semelhante, em que a previsão de 1 hora à frente possui os melhores resultados. Os erros começam a aumentar conforme o horizonte de previsão aumenta e, para 24 horas à frente, os resultados se aproximam novamente aos valores dos menores horizontes de tempo.

Bem como foi comentado anteriormente as previsões da velocidade do vento 24 horas à frente tiveram como resultado métricas estatísticas semelhantes às obtidas para as previsões de 1 e 3 horas à frente, tanto para a altura de 25 quanto para a de 50 metros. Especula-se que, devido às características de clima semiárido tropical, a região não é afetada por eventos sinóticos. Assim, fica bem definida a repetição do

ciclo diurno da camada limite (por forçantes locais) e, por esse motivo, as previsões para o horizonte de 24 horas ficaram melhores que para os horizontes de 6, 12 e 18 horas.

Verifica-se, também, que o modelo teve tendência de subestimar os resultados, visto o resultado do erro percentual, o qual é negativo. Isso indica que os valores observados são superiores ao valor que foi modelado pela RNA.

De modo geral os resultados da rede neural artificial RBF foram satisfatórios. Para uma hora à frente, o estudo de Pessanha, Castellani e Lima (2011) apresentou características finais (REQM igual a 1,13 m/s e EMA igual a 0,83 m/s) semelhantes aos resultados aqui encontrados (REQM igual a 1,08 m/s e EMA igual a 0,84 m/s).

Resultados parecidos também foram encontrados por Hiruma (2016), os quais abrangem EMA entre 0,80 a 0,83 m/s e REQM entre 1,06 a 1,09 m/s para o horizonte de 1 hora. Para o horizonte de 3 horas, as estimativas obtidas foram mais próximas da realidade que no estudo de Hiruma (2016), em que os resultados da REQM variaram de 1,76 a 1,93 m/s e do EMA de 1,37 a 1,48 m/s, enquanto o encontrado neste trabalho foi uma REQM de 1,11 m/s e um EMA de 0,86 m/s. O mesmo ocorreu para a previsão de 6 horas à frente.

Para um horizonte de um dia à frente, Santos (2019) encontrou valores de velocidade do vento com REQM de 1,18 m/s, estimativa esta muito parecida com o valor que REQM (1,16 m/s) obtidos neste trabalho.

5 CONCLUSÕES E RECOMENDAÇÕES

Como motivação para esse estudo, observou-se inicialmente que o emprego de métodos capazes de realizar a previsão da velocidade do vento a curto prazo pode contribuir na redução das incertezas referentes à geração de energia eólica e, com isso, auxiliar no planejamento da operação das usinas despachadas pelo Operador Nacional do Sistema (ONS).

Neste trabalho, diferentes horizontes de tempo em curto prazo foram analisados a fim de verificar o desempenho da previsão da velocidade do vento através de uma rede neural artificial RBF. Os resultados aqui obtidos comprovaram a dificuldade de se realizar a previsão das velocidades do vento, especialmente quando o horizonte de previsão aumenta. Ademais, foi visto que para 24 horas à frente o desempenho da RNA foi semelhante ao desempenho da previsão de 1 e 3 horas à frente, devido à repetição do ciclo diurno da camada limite na região estudada.

De forma geral, os valores modelados pela RNA foram considerados competitivos ou melhores quando comparados a outros estudos publicados na literatura. Porém, cada localidade possui características de vento próprias e essas especificidades devem ser consideradas. Além disso, fatores como resoluções temporais, métodos utilizados, variáveis disponíveis e tamanho das séries de dados também podem influenciar na geração de resultados diferentes.

Portanto, conclui-se que os objetivos gerais e os objetivos específicos definidos inicialmente para este estudo foram atingidos.

Para trabalhos futuros sugere-se que seja feito um treinamento especializado da RNA, isto é, realizar o treinamento em etapas, cada um referente a uma época do ano, de modo que a sazonalidade existente seja melhor representada.

Recomenda-se, também, avaliar a previsão da velocidade do vento com horizontes de tempo maiores, ainda considerando um horizonte de curto prazo (até 72 horas), a fim de gerar uma segurança ainda maior no setor de energia elétrica.

Por fim, é sugerida a busca por outras variáveis preditoras da rede neural, como a precipitação, a qual pode estar vinculada com a sazonalidade da velocidade do vento na área de estudo, e medições de velocidade do vento em outras estações, desde que sejam próximas ao local de estudo (Petrolina – PE).

REFERÊNCIAS

- ABEEÓLICA, 2020. **Dia Mundial do Vento: Brasil completa 16 GW de capacidade instalada de energia eólica.** Disponível em: <<http://abeeolica.org.br/noticias/dia-mundial-do-vento-brasil-completa-16-gw-de-capacidade-instalada-de-energia-eolica/>>. Acesso em: 10/11/2020.
- AMARANTE, O. A. C.; BROWER, M.; ZACK, J.; SÁ, A. L. de. Atlas do Potencial Eólico Brasileiro. Brasília, 2001.
- ANDRADE, A.; LUFT, C. D. B.; ROLIM, M. K. S. B. O desenvolvimento motor, a maturação das áreas. **Efdeportes**, Buenos Aires, v. 10, n. 78, p. 10. Novembro de 2004.
- ANDRADE, T. D. Inovação tecnológica e meio ambiente: a construção de novos enfoques. **Ambiente & Sociedade**, Campinas, v. VII, n. 1, p. 18, Jan-Jul 2004. ISSN 1809-4422.
- ANEEL. Agência Nacional de Energia Elétrica. Atlas de Energia Elétrica do Brasil, 2005.
- BRANDÃO, A.L.R. **O turismo convencional e o contra-hegemônico de canoa quebrada e Jericoacoara – CE.** 2014. 158p. Dissertação (Mestrado em Gestão de Negócios Turísticos) – Universidade Estadual do Ceará, Fortaleza, 2014.
- BRANQUINHO, A. **Redes Neurais Artificiais (Introdução):** Parte 1. 2013. (20m25s). Disponível em: <<https://www.youtube.com/watch?v=vbf4IzvXvuM>>. Acesso em: 22/09/2019.
- BRISK, V. **Previsões de vazão diária para a bacia do alto Iguaçu com o emprego de redes neurais artificiais RBF.** 2016. 91p. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental) – Universidade Federal do Paraná, Curitiba, 2016.
- CABRAL, I.G. **Previsões de vazão diária para a bacia do alto Iguaçu com o emprego de redes neurais artificiais.** 2013. 99p. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental) – Universidade Federal do Paraná, Curitiba, 2013.
- CARVALHO, C.A.V de. **Análise de previsão de itens de demanda intermitente utilizando o modelo syntetos-boylan aproximatio.** 2012. 61p. Dissertação (Mestrado em Administração de Empresas) – Fundação Instituto Capixaba de Pesquisas em Contabilidade, Economia e Finanças, Vitória, 2012.
- CCEE. Câmara de Comercialização de Energia Elétrica. **Energia de Reserva.** 2020. Disponível em: <https://www.ccee.org.br/portal/faces/oquefazemos_menu_lateral/energia_reserva>. Acesso em:13/10/2020.

CCEE. Câmara de Comercialização de Energia Elétrica. **Fontes**. 2019. Disponível em: <https://www.ccee.org.br/portal/faces/pages_publico/onde-atuamos/fontes>. Acesso em: 13/10/2019.

COELHO, L. D. S. Rede neural com função de base radial com treinamento usando filtro de Kalman e entropia cruzada aplicada à identificação de sistemas, Curitiba, 2007. 6p.

COIMBRA, I.L. et al. Análise da previsão do vento em um parque eólico costeiro no nordeste brasileiro. In: CONGRESSO BRASILEIRO DE ENERGIA SOLAR, VII, 2018, Gramado. Anais...Florianópolis: UFSC, 2018. Disponível em: <<https://anaiscbens.emnuvens.com.br/cbens/article/view/619>>.

COPEL. Eólica: Por que aproveitar o vento para gerar energia? 2016. Disponível em <<https://www.copel.com/hpcopel/root/nivel2.jsp?endereco=%2Fhpcopel%2Froot%2Fpagcopel2.nsf%2Fdocs%2F301DC3A7702B129303257405005C2FDB>>.

COSTA, R.C. **Modelos preditivos de velocidade de vento para sistemas eólicos baseados em redes neurais artificiais**. 2016. 66p. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Universidade Federal da Paraíba, João Pessoa, 2016.

CPFL, 2019. CPFL Soluções. Mercado de energia elétrica: tudo o que você precisa saber. Disponível em: < <https://cpflsolucoes.com.br/blog/mercado-de-energia-eletrica-tudo-o-que-voce-precisa-saber/>>. Acesso em: 10 Novembro 2019.

CPTEC. Centro de Previsão de Tempo e Estudos Climáticos. **Glossários: Princípios de Meteorologia e Meio Ambiente**. 2018. Disponível em: <<https://www.cptec.inpe.br/glossario.shtml>>. Acesso em: 26/11/2020.

CRESESB. **História da Energia Eólica e suas utilizações**. 2017. Disponível em: <http://www.cresesb.cepel.br/index.php?section=com_content&cid=tutorial_eolica>.

CRESESB. **O Recurso Eólico**. 2008. Disponível em: <http://www.cresesb.cepel.br/index.php?section=com_content&lang=pt&cid=211>.

DALMAZ, A. **Estudo do potencial eólico e previsão de ventos para geração de eletricidade em Santa Catarina**. 2007. 193p. Dissertação (Mestrado em Engenharia Mecânica) – Universidade Federal de Santa Catarina, Florianópolis, 2007.

DOMINGUES, M. L. C. S. **Mineração de Dados Utilizando Aprendizado Não-Supervisionado: um estudo de caso para bancos de dados de saúde**. 2003. 127p. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2003.

DSA DATA SCIENCE ACADEMY. Deep learning, [2019]. Disponível em: <<http://deeplearningbook.com.br/>>. Acesso em: 10 aug. 2019.

ENEL GREEN POWER. Energias Renováveis. 2020. Disponível em: <<https://www.enelgreenpower.com/pt/learning-hub/energias-renoveveis>>. Acesso em: 23/10/2020.

EPE. Empresa de Pesquisa Energética. **Balço Energético Nacional 2019 - Ano Base 2018**. Rio de Janeiro, p. 67. 2019a.

EPE. Empresa de Pesquisa Energética. **Balço Energético Nacional 2020 - Ano Base 2019**. Rio de Janeiro, p. 73. 2020a.

EPE. Empresa de Pesquisa Energética. **Fontes de Energia**. 2020b. Disponível em: <<https://www.epe.gov.br/pt/abcdenergia/fontes-de-energia>>. Acesso em: 26/11/2020.

EPE. Empresa de Pesquisa Energética. **Matriz Energética e Elétrica**. 2019b. Disponível em: <<http://www.epe.gov.br/pt/abcdenergia/matriz-energetica-e-eletrica>>. Acesso em: 12/10/2019.

EPE. Empresa de Pesquisa Energética. **Matriz Energética e Elétrica**. 2020c. Disponível em: <<https://www.epe.gov.br/pt/abcdenergia/matriz-energetica-e-eletrica>>. Acesso em: 05/03/2021.

FERREIRA, A.A.B. **Metodologia de previsão do potencial eólico de curto prazo para planejamento da operação de sistemas elétricos**. 2012. 97p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Pampa, Alegrete, 2012.

FUJISE, J. **Desenvolvimento de Modelo de Previsão de Geração Eólica para Planejamento Energético Utilizando Redes Neurais Artificiais**. 2018. 68p. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2018.

GAVINO, N.A. **Energia Eólica: uma análise dos incentivos à produção (2002-2009)**. 2011. 115p. Monografia (Especialização) - Curso de Instituto de Economia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2011.

GONÇALVES, L. de F. **O método da correlação cruzada destendenciada em séries temporais**. 2018. 38p. Trabalho de Conclusão de Curso (Graduação em Estatística) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2018.

HIRUMA, F. S. **Previsão da geração de energia eólica com redes neurais artificiais**. 2016. 168p. Dissertação (Mestrado em Engenharia de Recursos Hídricos e Ambiental) – Universidade Federal do Paraná, Curitiba, 2016.

IRENA. International Renewable Energy Agency. **Renewable Capacity Statistics 2020**. Abu Dhabi, p. 66. 2020a.

IRENA. International Renewable Energy Agency. **Wind Energy**. 2020b. Disponível em: <<https://irena.org/wind>>. Acesso em: 02/12/2020.

KHOURY, F.K.C.B. **Minimização de custos de produção via programação inteira mista: estudo de caso de planejamento de produção de luminárias.** 2011. 114p. Dissertação (Mestrado em Engenharia Industrial) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2011.

LAMARÃO, S. T. D. N. A energia elétrica como campo de pesquisa historiográfica no Brasil. AMERICA LATINA EN LA HISTORIA ECONOMICA, Cidade do México, v. 8, p. 11, Jul-Dez 1997. ISSN 2007-3496.

LI, G.; SHI, J. On comparing three artificial neural networks for wind speed forecasting. Applied Energy, London, v. 87, n. 7, p. 2313-2320, 2010.

LINARD, F.J.A. **Estimativas da velocidade do vento em altitude usando o software windographer.** 2010. 42p. Monografia (Graduação em Bacharelado em Física) – Universidade Estadual do Ceará, Fortaleza, 2010.

MARTINS, F.R; GUARNIERI R.A.; PEREIRA E.B. O aproveitamento da energia eólica. **Revista brasileira de ensino de física**, São Paulo, v30, n.1, p. 1-13, out. 2007.

MINUZZI, A.W. **Estudos de metodologias de avaliação do vento para aplicação no Campus Alegrete.** 2011. 95p. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Universidade Federal do Pampa, Alegrete, 2011.

MME. **Energia eólica no Brasil e mundo: ano de referência 2015.** Ministério de Minas e Energia. Brasília, p. 8. 2016.

MME. **Energia no mundo: 2015-2016.** Ministério de Minas e Energia. Brasília, p. 42. 2017.

NICOLAU, L. **Redes Neurais Artificiais.** 2016. 29 slides. Disponível em: < <http://www.cear.ufpb.br/juan/wp-content/uploads/2016/08/Aula-3c-Funções-de-Ativação-e-Gradiente-Descendente.pdf> >. Acesso em: 22/09/2019.

PESSANHA, J.F.M; CASTELLANI, V.; LIMA, C. Técnicas de Inteligência Computacional na Previsão de Séries de Velocidade de Vento: Uma Comparação da Lógica Nebulosa com Redes Neurais Artificiais. In: Seminário Nacional de Produção e Transmissão de Energia Elétrica, XXI, 2011, Florianópolis. Anais... Rio de Janeiro: SNPTEE, 2011. 8 p.

REMES, C.L. **Caracterização por simulação numérica de painéis fotovoltaicos e método de rastreamento do máximo ponto de potência baseado em redes neurais artificiais.** 2013. 92p. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Universidade do Estado de Santa Catarina, Joinville, 2013.

RODRIGUES, G.C. **Utilização de redes neurais para previsão de ventos no horizonte de 24 horas.** 2007. 119p. Dissertação (Mestrado em Energia Elétrica) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2007.

ROSA, J.L.G. **Redes de Função de Base Radial**. 2011. 71 slides. Disponível em: <<http://wiki.icmc.usp.br/images/e/e8/SCC5809Cap6.pdf>>. Acesso em: 10/10/2019.

ROSSI, D.J. **Previsão da velocidade dos ventos por redes neurais artificiais e ARIMA de Box & Jenkins**. 2013. 76p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual Paulista Júlio de Mesquita Filho, Ilha Solteira, 2013.

SANTOS, F. K. M. dos. **Redes neurais artificiais e suas aplicabilidades: modelagem do valor da temperatura máxima na cidade de Castanhal**. 2018. 57p. Trabalho de Conclusão de Curso (Graduação em Matemática) – Universidade Federal do Pará, Castanhal, 2018.

SANTOS, I. G. da S. **Previsão da velocidade do vento na escala do parque eólico utilizando o modelo WRF e rede neural artificial**. 2019. 76p. Dissertação (Pós Graduação em Meteorologia) – Universidade Federal de Alagoas, Maceió, 2019.

SEVERO, D. da S. **Otimização Global em Redes Neurais Artificiais**. 2010. 63p. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – Universidade Federal de Pernambuco, Recife, 2010.

SHAMSHIRBAND, S. et al. Wind turbine power coefficient estimation by soft computing methodologies: Comparative study. **Energy Conversion and Management**, n. 81, pp.520-526. 2014.

SILVA, G.F. **Análise de Complexidade de séries temporais de velocidade do vento utilizando Sample Entropy e Cross-Sample Entropy**. 2016. 64p. Dissertação (Pós-Graduação em Biometria e Estatística Aplicada) – Universidade Federal Rural de Pernambuco, Recife, 2016.

SILVA, G.R. **Características de vento da região Nordeste**. 2003. 141p. Dissertação (Mestrado em Engenharia Mecânica) – Universidade Federal de Pernambuco, Recife, 2003.

SILVA, I. N. da; AMARAL, W. C. do; ARRUDA, L. V. R. de. Uma abordagem usando redes neurais artificiais para resolução de problemas de otimização restrita. **Pesqui. Oper.**, Rio de Janeiro, 2004. v. 24, n. 2, p. 285-302. 2004. <https://doi.org/10.1590/S0101-74382004000200005>.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.; **Redes neurais artificiais: para engenharia e ciências aplicadas**. Artliber, São Paulo, 2010.

SILVA, L.N. de C. **Análise e síntese de estratégias de aprendizado para redes neurais artificiais**. 1998. 247p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual de Campinas, Campinas, 1998.

SILVA, N.B. **Aplicação de métodos estatísticos e redes neurais no pós-processamento de produtos de previsão numérica de tempo**. 2007. 216p.

Dissertação (Mestrado em Engenharia Civil) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2007.

SILVA, P.J. **Estrutura para identificação e avaliação de impactos ambientais em obras hidroviárias**. 2004. 553p. Tese (Doutorado em Engenharia Hidráulica) – Universidade de São Paulo, São Paulo, 2004.

SILVA, P.K. de O. **Análise e previsão de curto prazo do vento através de modelagem estatística em áreas de potencial eólico no nordeste do Brasil**. 2017. 168p. Tese (Doutorado em Meteorologia) – Universidade Federal de Campina Grande, Campina Grande, 2017.

SILVEIRA, A.B. **Desenvolvimento e aplicação de um modelo de ajuste de campo de vento para a região da Grande Vitória – ES**. 2007. 81p. Dissertação (Mestrado em Engenharia Ambiental) – Universidade Federal do Espírito Santo, Vitória, 2007.

SONDA, Sistema de Organização Nacional de Dados Ambientais – CPTEC/INPE. [online]: <http://sonda.ccst.inpe.br/>, 2006.

STULL, ROLAND. **Meteorology for scientists and engineers**. 2ed. Belmont, CA: Brooks/Cole, 1999. 528p.

TOMASINI, J. **Padrão de variabilidade do vento à superfície, em Lajeado, Rio Grande do Sul, Brasil: Implicações Ambientais**. 2011. 59p. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental) – Centro Universitário Univates, Lajeado, 2011.

TSCHÖKE, G.V. **Emprego de redes neurais artificiais para elaboração de prognósticos sazonais de anomalias climáticas para o estado do Paraná**. 2011. 78p. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental) – Universidade Federal do Paraná, Curitiba, 2011.

VARELLA, J, L.; QUADRELLI, G. Redes Neurais e análise de potência. **Revista de tecnologia aplicada**, v6, n.3, p. 33-45, set-dez. 2017.

VARGAS, S.A. **Previsão da distribuição da densidade de probabilidade da geração de energia eólica usando técnicas não paramétricas**. 2016. 191p. Tese (Doutorado em Engenharia Elétrica) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2015.

VILLANUEVA, J.M.M. **Redes Neurais Artificiais (RNA): Definições**. 2016. 48 slides. Disponível em: <<http://www.cear.ufpb.br/juan/wp-content/uploads/2016/08/Aula-3a-Redes-Neurais-Artificias-Definições.pdf>>. Acesso em: 20/08/2019.

ZUBEN, F.J.V. Redes Neurais Artificiais. Notas de Aula da disciplina Introdução à Computação Natural. 2009.

APÊNDICE 1 — RESULTADOS DO MÉTODO DE REGRESSÃO

1.1 VELOCIDADE DO VENTO EM 25 METROS

1.1.1 HORIZONTE DE PREVISÃO DE 1 HORA

Nas Figuras 1.1, 1.2 e 1.3 estão expressos os resultados do método *screening regression* dos três ciclos realizados para o horizonte de 1 hora à frente.

FIGURA 1.1 – RESULTADO DO PRIMEIRO CICLO.

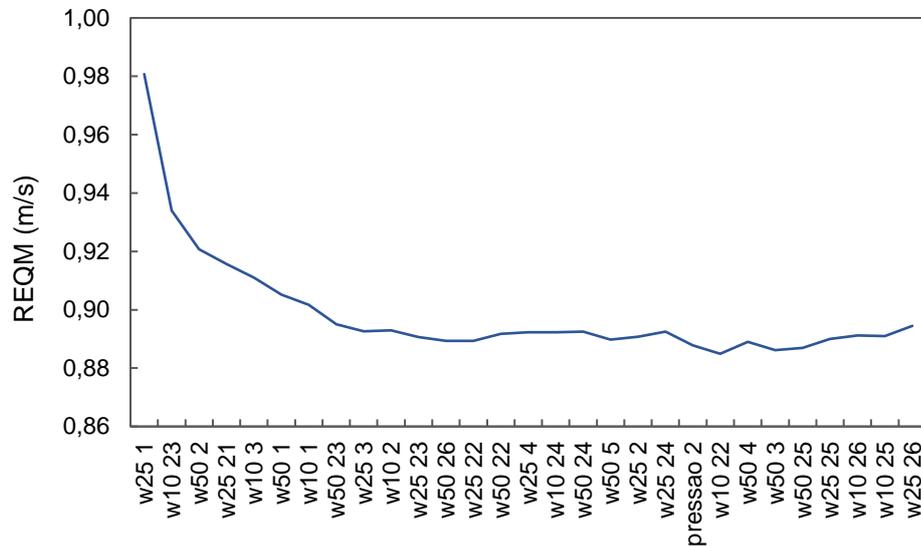


FIGURA 1.2 – RESULTADO DO SEGUNDO CICLO

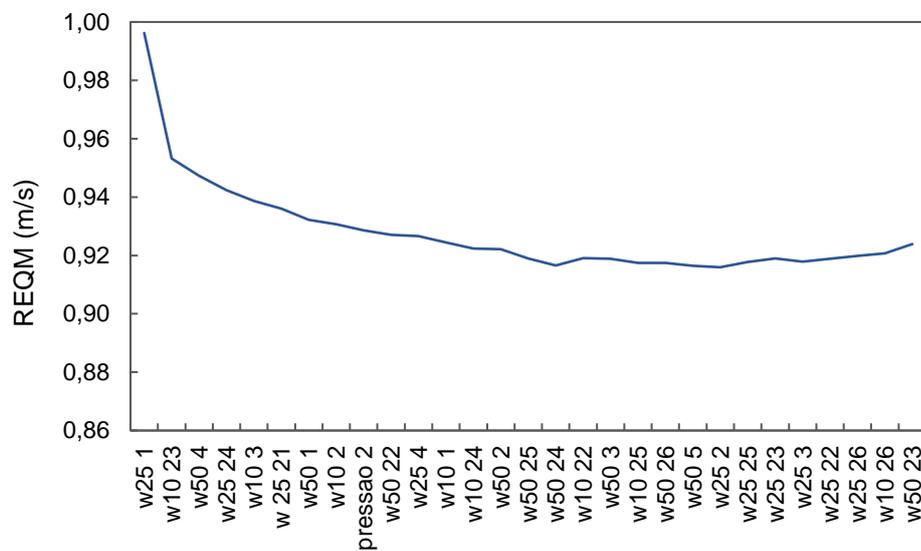
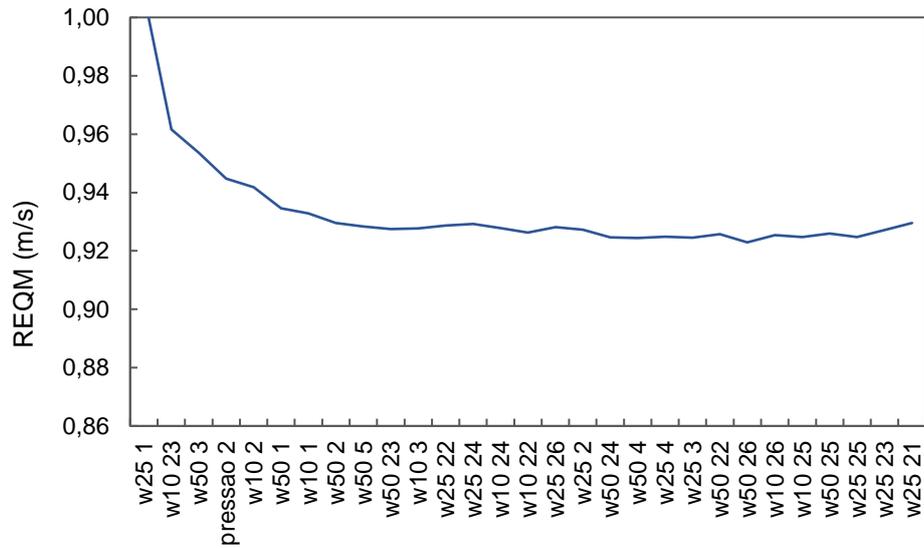


FIGURA 1.3 – RESULTADO DO TERCEIRO CICLO



1.1.2 HORIZONTE DE PREVISÃO DE 3 HORAS

Nas Figuras 1.4, 1.5 e 1.6 estão expressos os resultados do método *screening regression* dos três ciclos realizados para o horizonte de 3 horas à frente.

FIGURA 1.4 – RESULTADO DO PRIMEIRO CICLO.

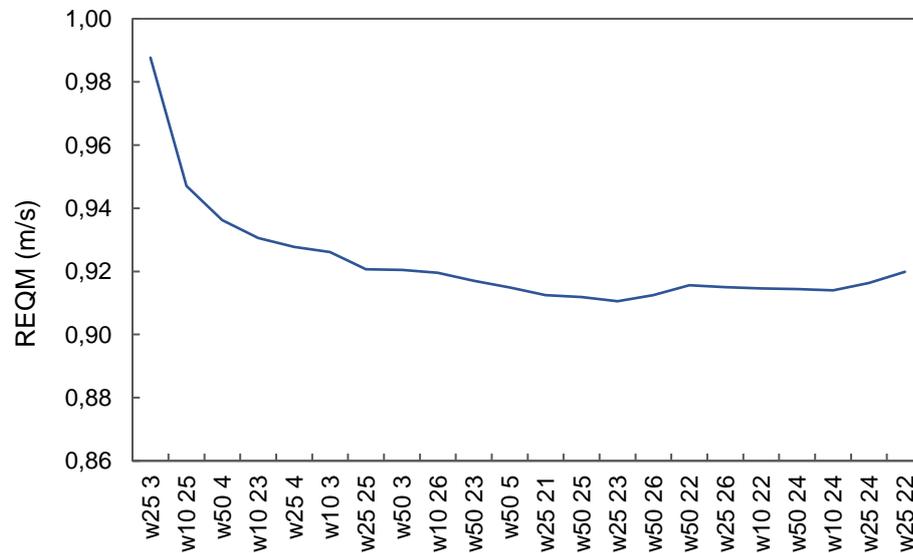


FIGURA 1.5 – RESULTADO DO SEGUNDO CICLO

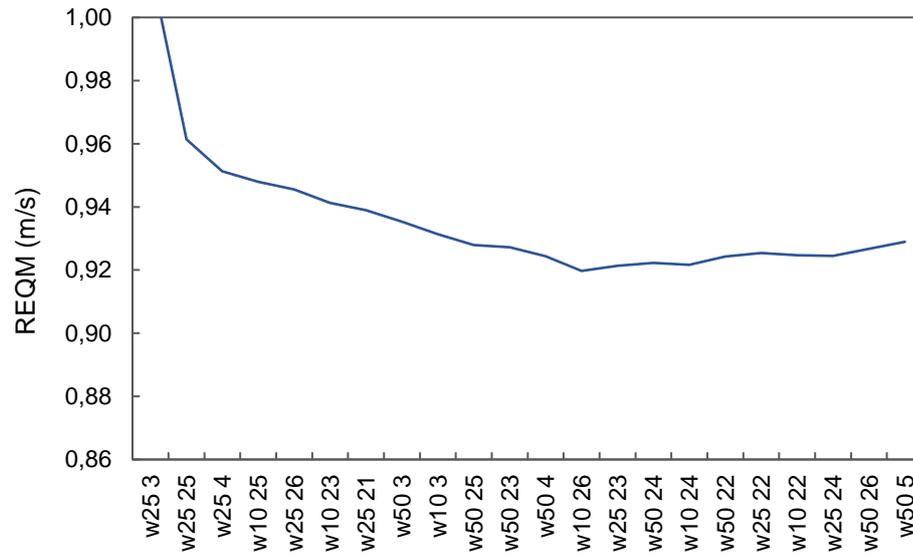
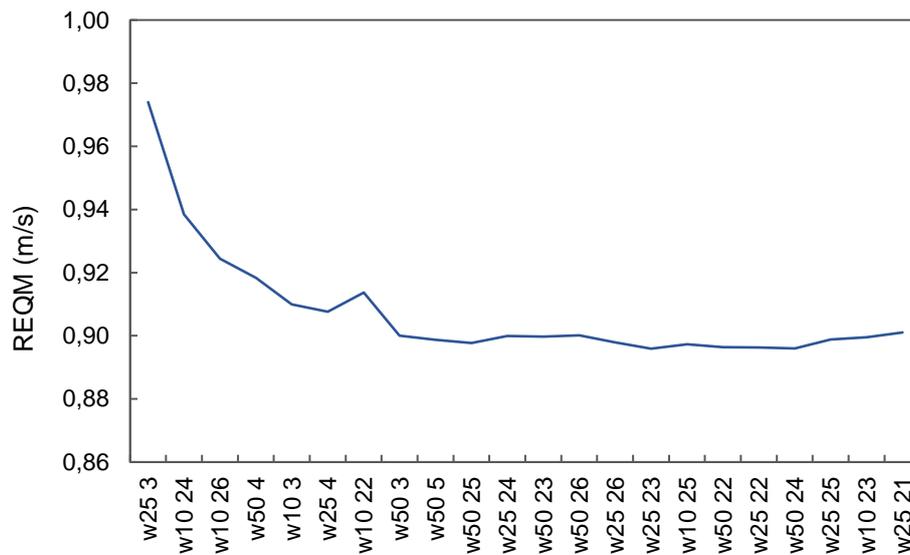


FIGURA 1.6 – RESULTADO DO TERCEIRO CICLO



1.1.3 HORIZONTE DE PREVISÃO DE 6 HORAS

Nas Figuras 1.7, 1.8 e 1.9 estão expressos os resultados do método *screening regression* dos três ciclos realizados para o horizonte de 6 horas à frente.

FIGURA 1.7 – RESULTADO DO PRIMEIRO CICLO.

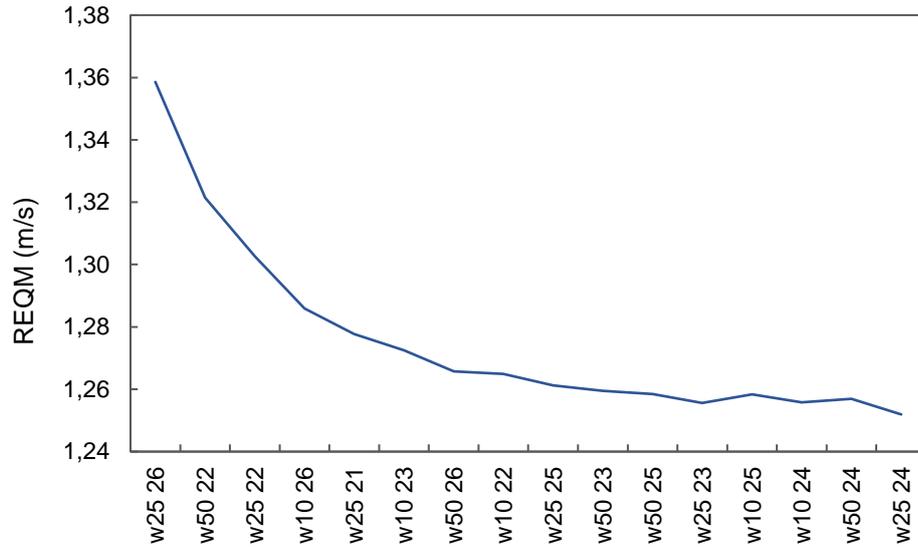


FIGURA 1.8 – RESULTADO DO SEGUNDO CICLO

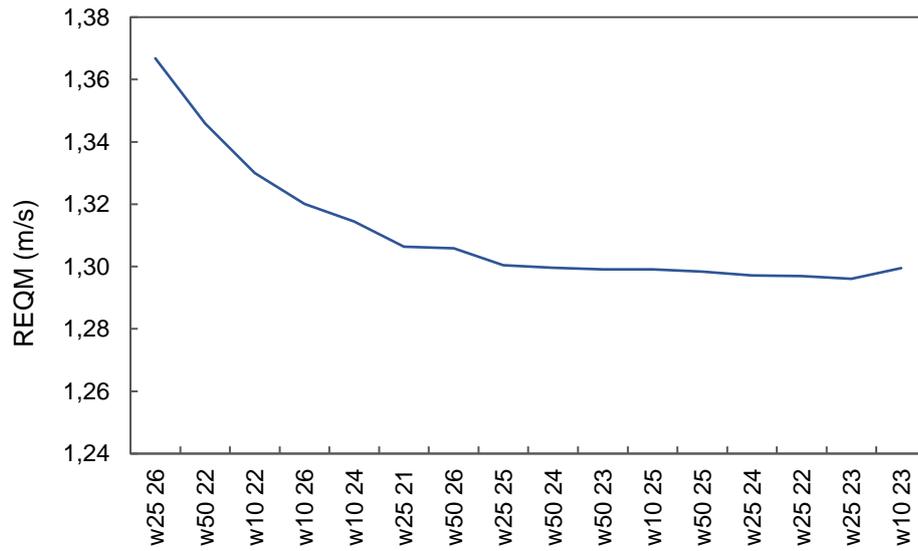
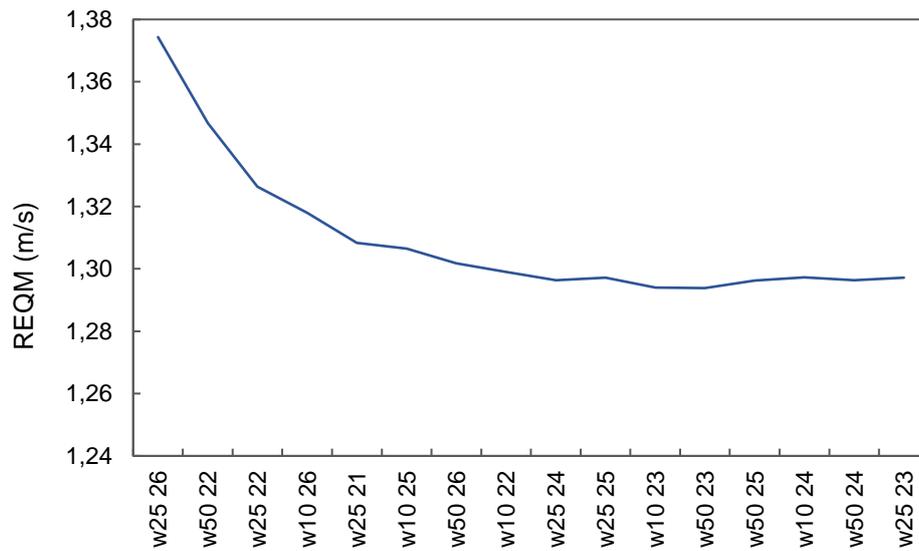


FIGURA 1.9 – RESULTADO DO TERCEIRO CICLO



1.1.4 HORIZONTE DE PREVISÃO DE 12 HORAS

Nas Figuras 1.10, 1.11 e 1.12 estão expressos os resultados do método *screening regression* dos três ciclos realizados para o horizonte de 12 horas à frente.

FIGURA 1.10 – RESULTADO DO PRIMEIRO CICLO.

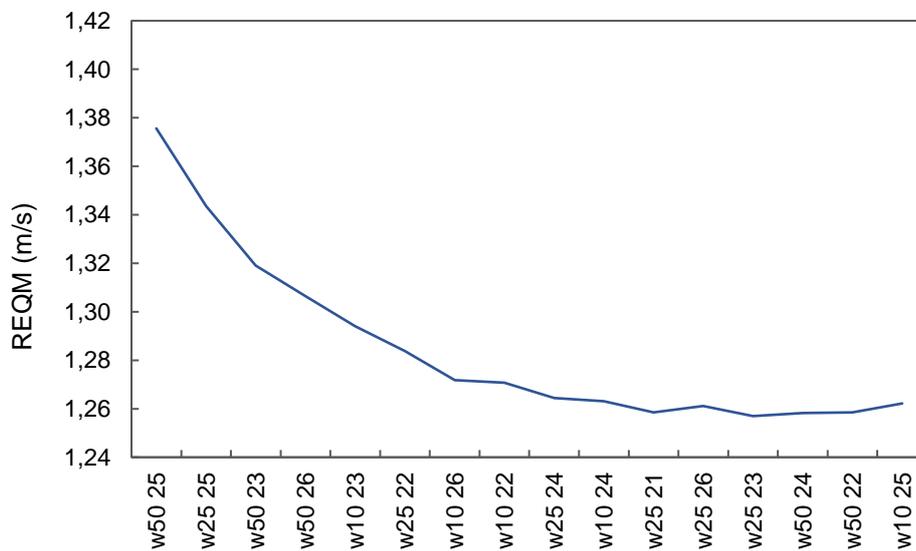


FIGURA 1.11 – RESULTADO DO SEGUNDO CICLO

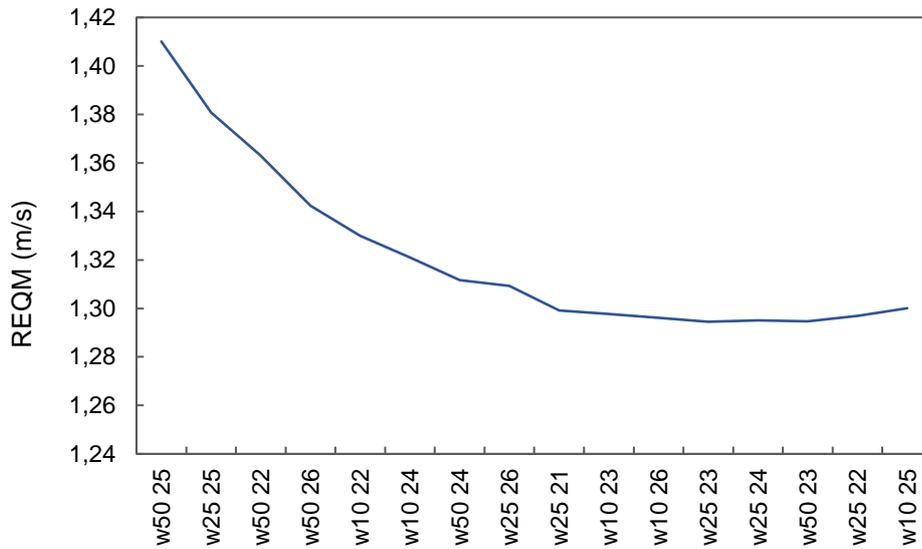
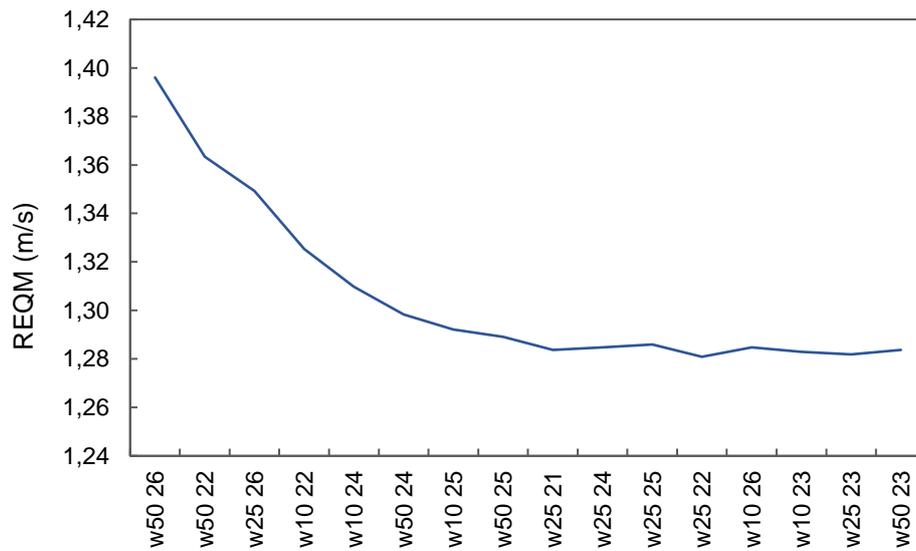


FIGURA 1.12 – RESULTADO DO TERCEIRO CICLO



1.1.5 HORIZONTE DE PREVISÃO DE 18 HORAS

Nas Figuras 1.13, 1.14 e 1.15 estão expressos os resultados do método *screening regression* dos três ciclos realizados para o horizonte de 18 horas à frente.

FIGURA 1.13 – RESULTADO DO PRIMEIRO CICLO.

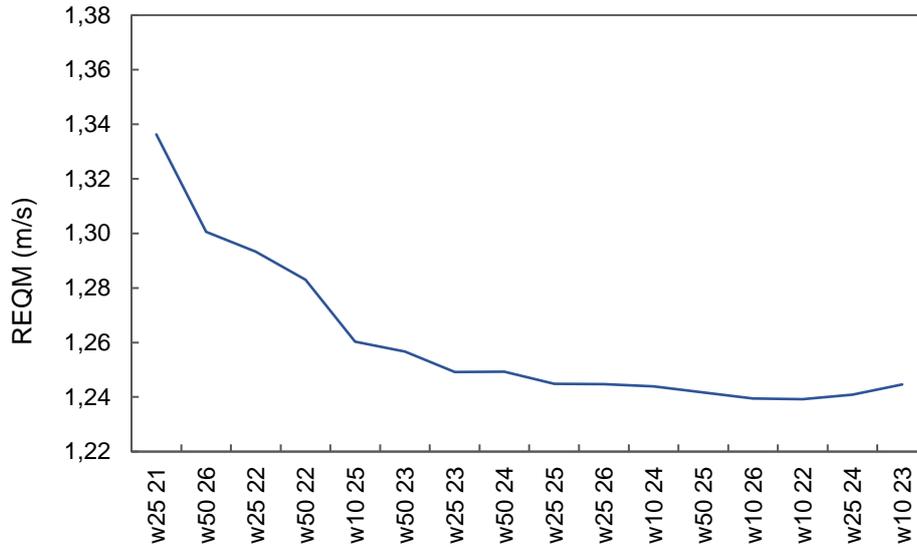


FIGURA 1.14 – RESULTADO DO SEGUNDO CICLO

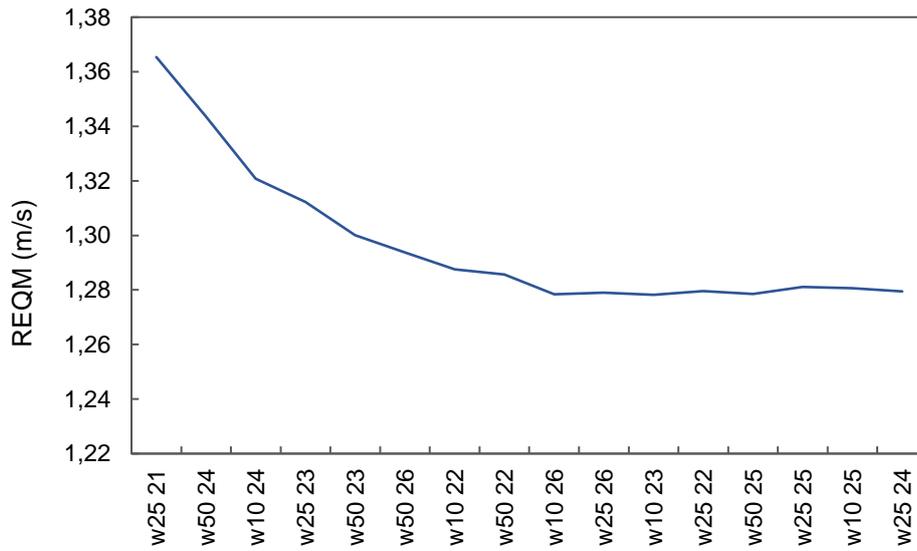
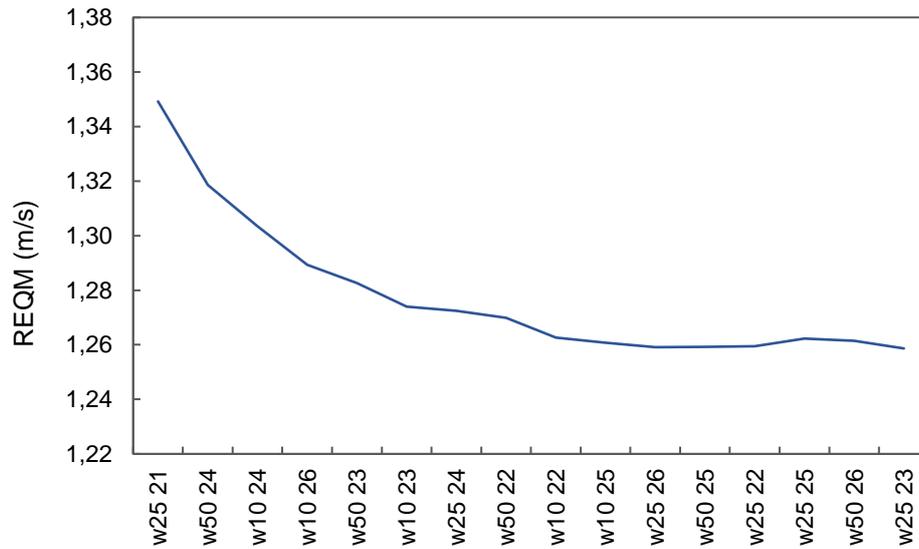


FIGURA 1.15 – RESULTADO DO TERCEIRO CICLO



1.1.6 HORIZONTE DE PREVISÃO DE 24 HORAS

Nas Figuras 1.16, 1.17 e 1.18 estão expressos os resultados do método *screening regression* dos três ciclos realizados para o horizonte de 24 horas à frente.

FIGURA 1.16 – RESULTADO DO PRIMEIRO CICLO.

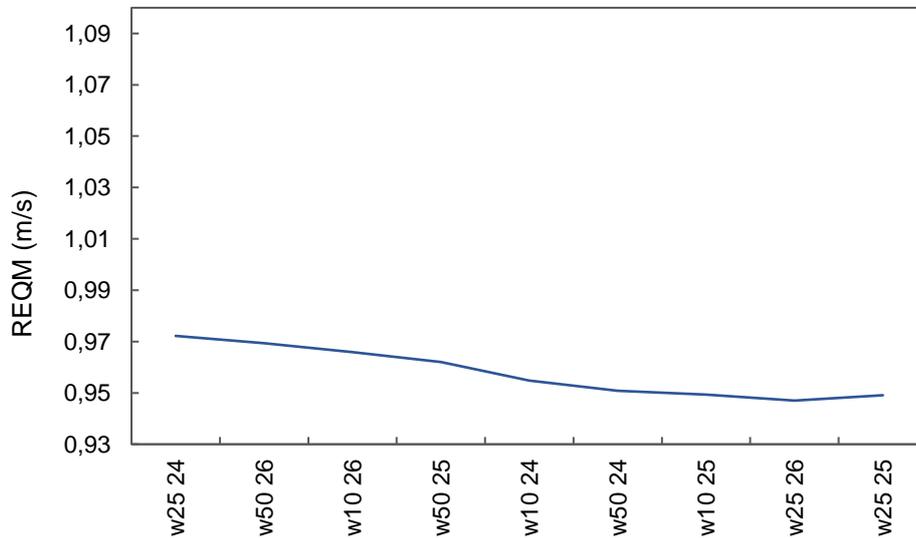


FIGURA 1.17 – RESULTADO DO SEGUNDO CICLO

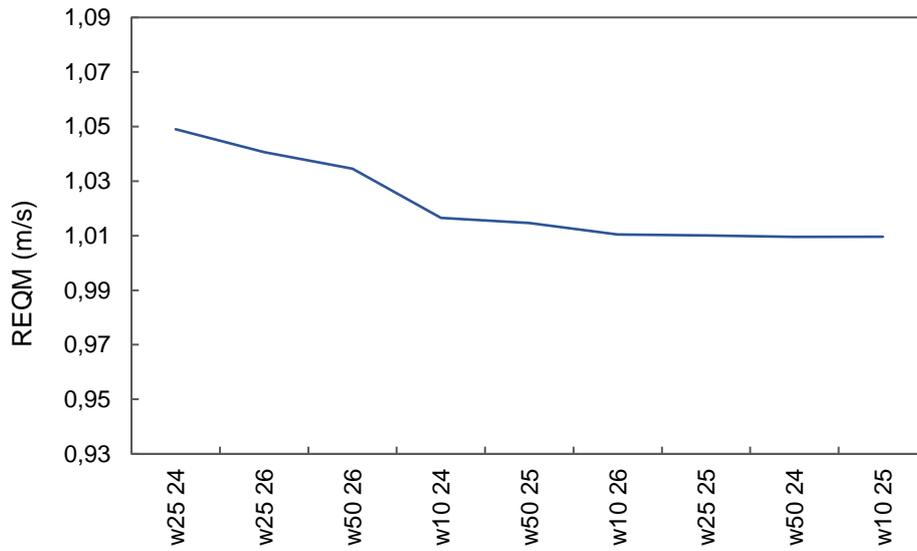
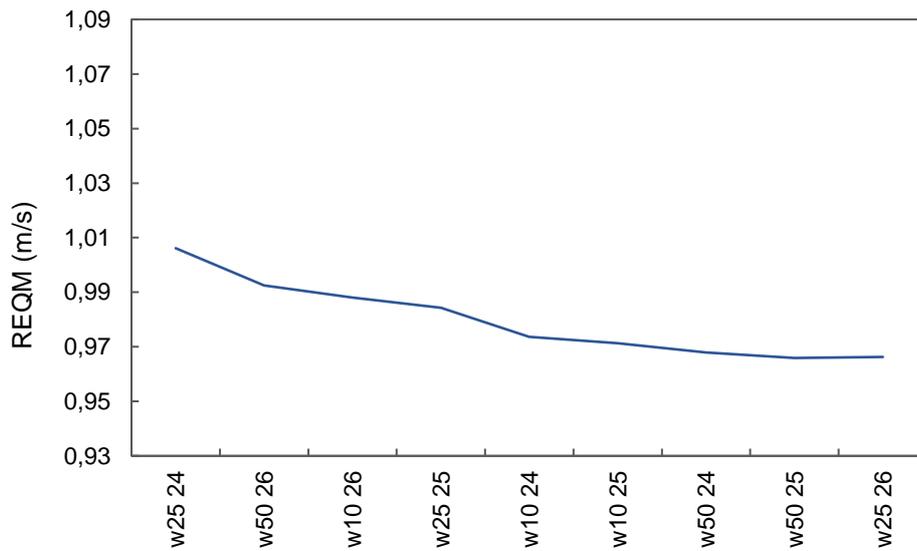


FIGURA 1.18 – RESULTADO DO TERCEIRO CICLO



1.2 VELOCIDADE DO VENTO EM 50 METROS

1.2.1 HORIZONTE DE PREVISÃO DE 1 HORA

Nas Figuras 1.19, 1.20 e 1.21 estão expressos os resultados do método *screening regression* dos três ciclos realizados para o horizonte de 1 hora à frente.

FIGURA 1.19 – RESULTADO DO PRIMEIRO CICLO.

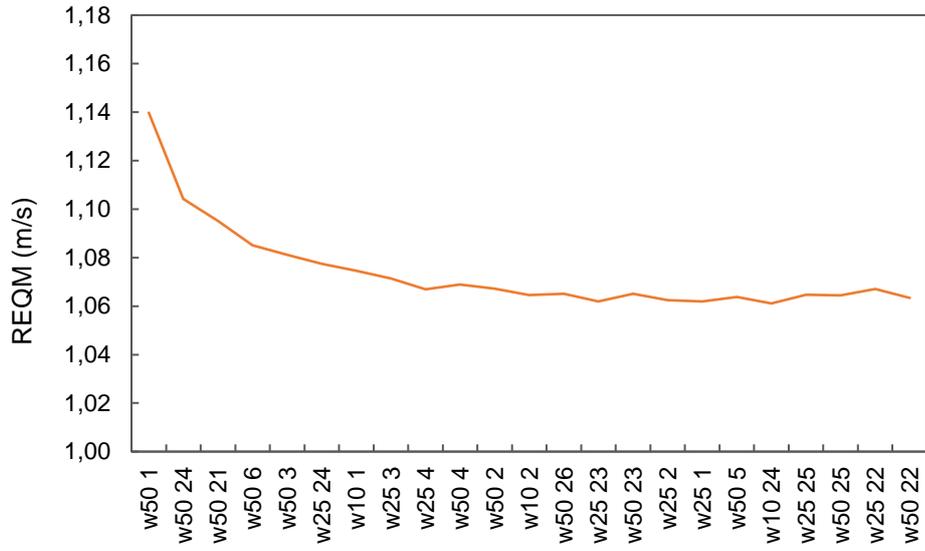


FIGURA 1.20 – RESULTADO DO SEGUNDO CICLO

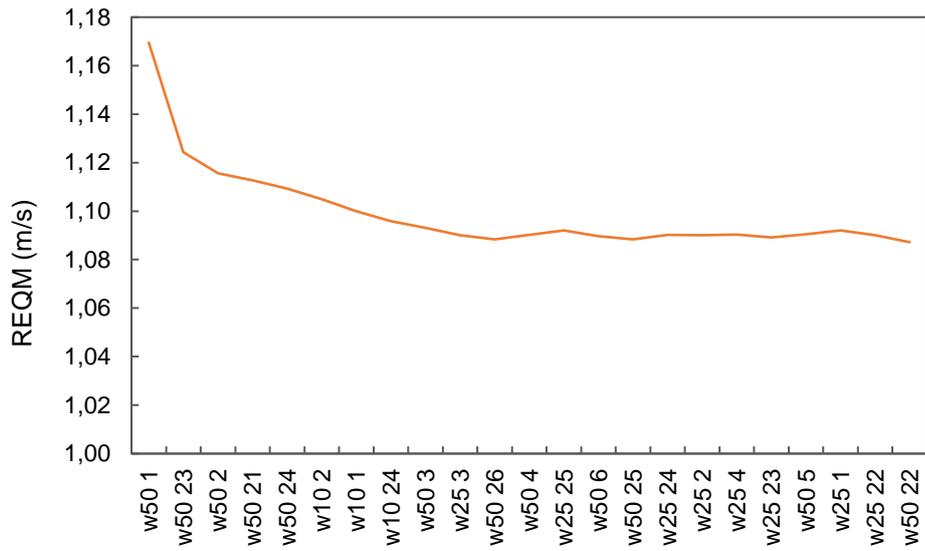
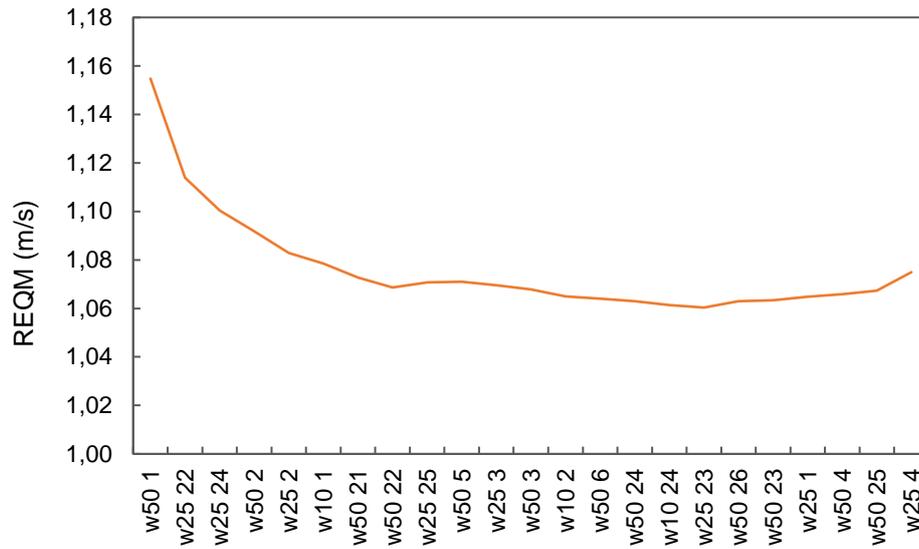


FIGURA 1.21 – RESULTADO DO TERCEIRO CICLO



1.2.2 HORIZONTE DE PREVISÃO DE 3 HORAS

Nas Figuras 1.22, 1.23 e 1.24 estão expressos os resultados do método *screening regression* dos três ciclos realizados para o horizonte de 3 horas à frente.

FIGURA 1.22 – RESULTADO DO PRIMEIRO CICLO.

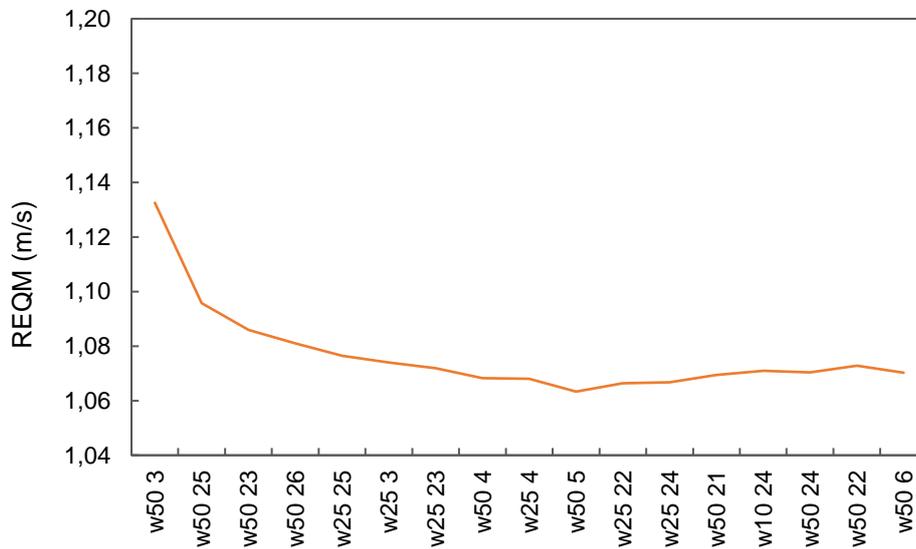


FIGURA 1.23 – RESULTADO DO SEGUNDO CICLO

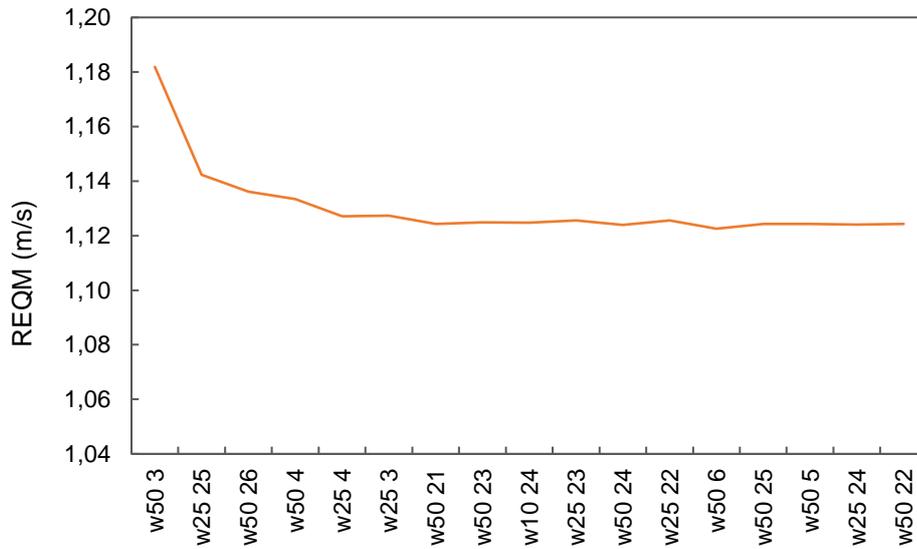
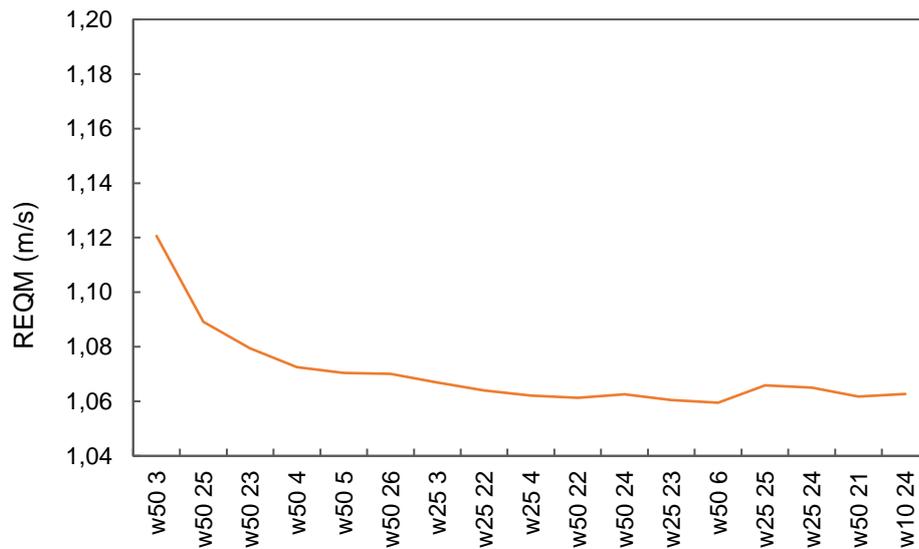


FIGURA 1.24 – RESULTADO DO TERCEIRO CICLO



1.2.3 HORIZONTE DE PREVISÃO DE 6 HORAS

Nas Figuras 1.25, 1.26 e 1.27 estão expressos os resultados do método *screening regression* dos três ciclos realizados para o horizonte de 6 horas à frente.

FIGURA 1.25 – RESULTADO DO PRIMEIRO CICLO.

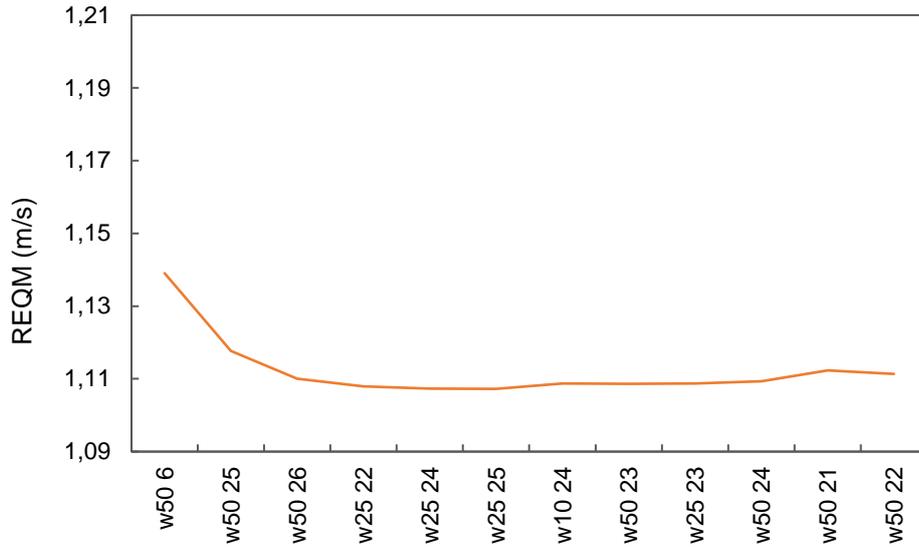


FIGURA 1.26 – RESULTADO DO SEGUNDO CICLO

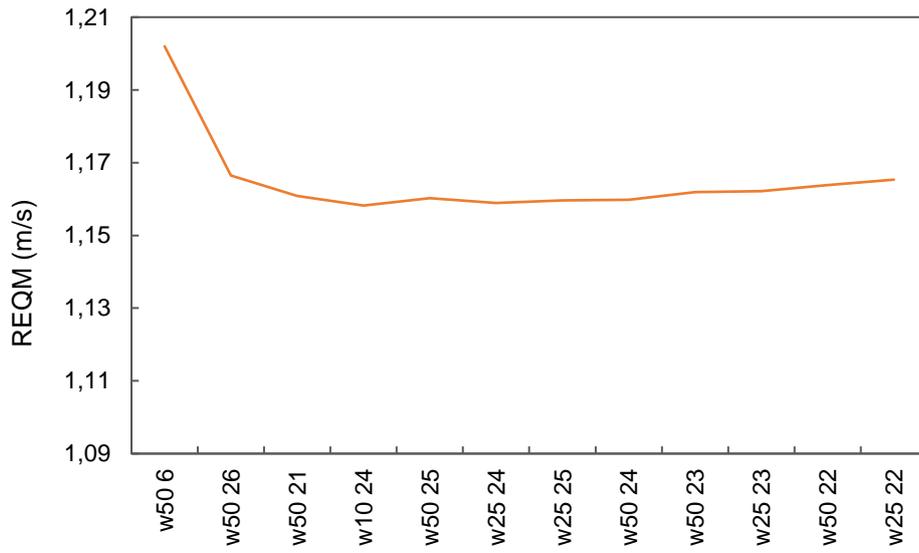
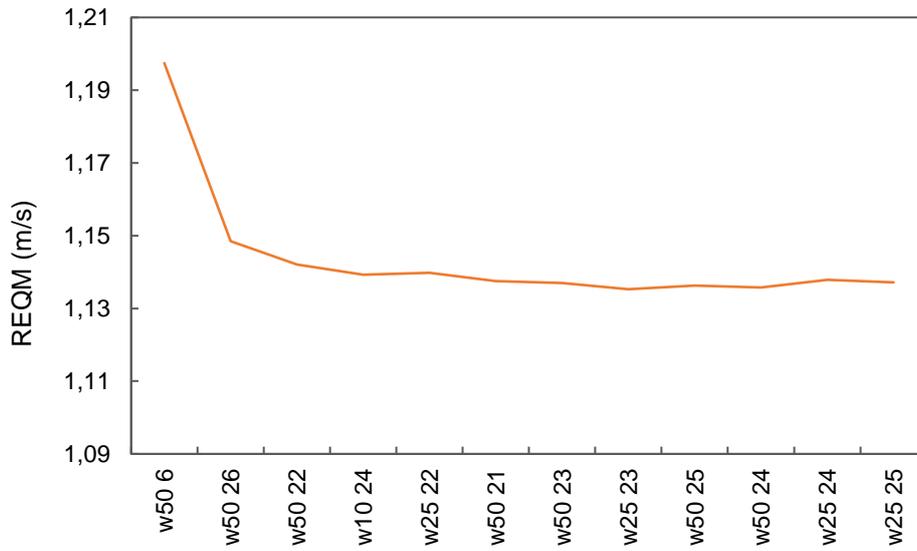


FIGURA 1.27 – RESULTADO DO TERCEIRO CICLO



1.2.4 HORIZONTE DE PREVISÃO DE 12 HORAS

Nas Figuras 1.28, 1.29 e 1.30 estão expressos os resultados do método *screening regression* dos três ciclos realizados para o horizonte de 12 horas à frente.

FIGURA 1.28 – RESULTADO DO PRIMEIRO CICLO.

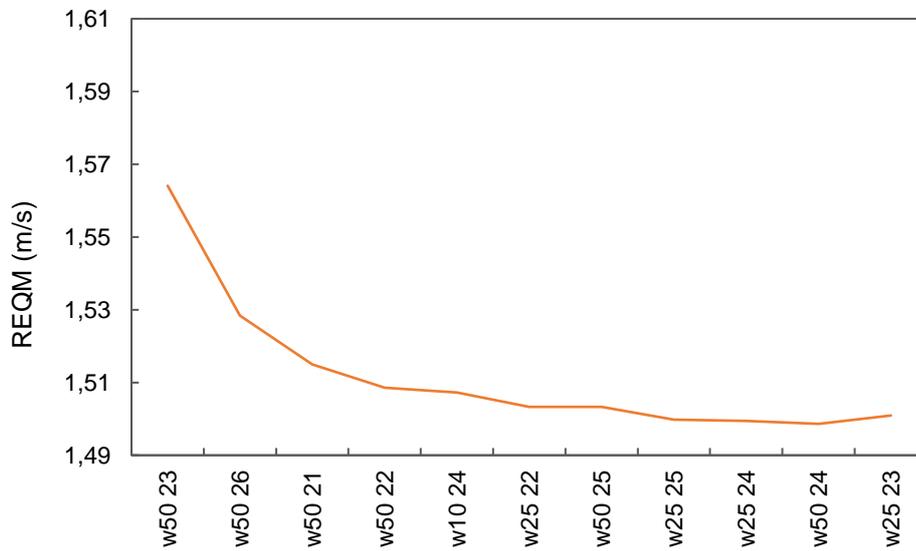


FIGURA 1.29 – RESULTADO DO SEGUNDO CICLO

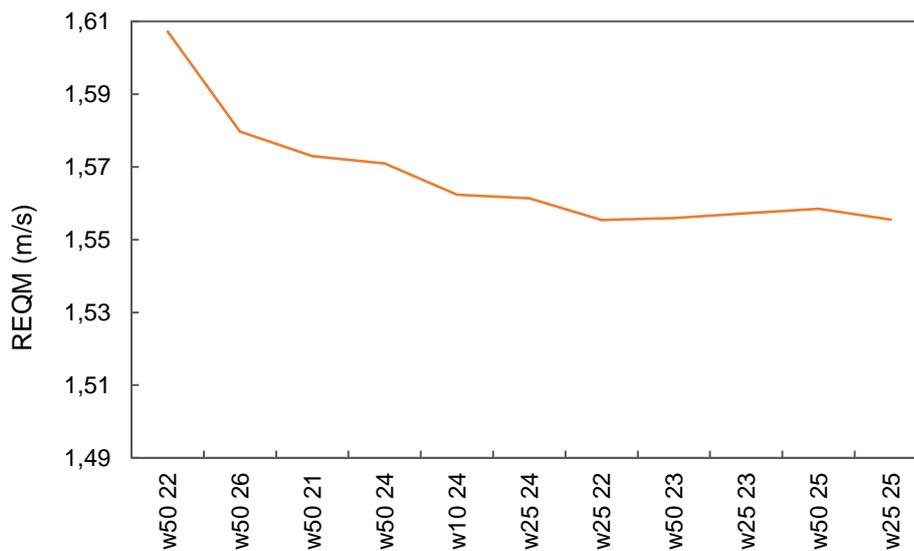
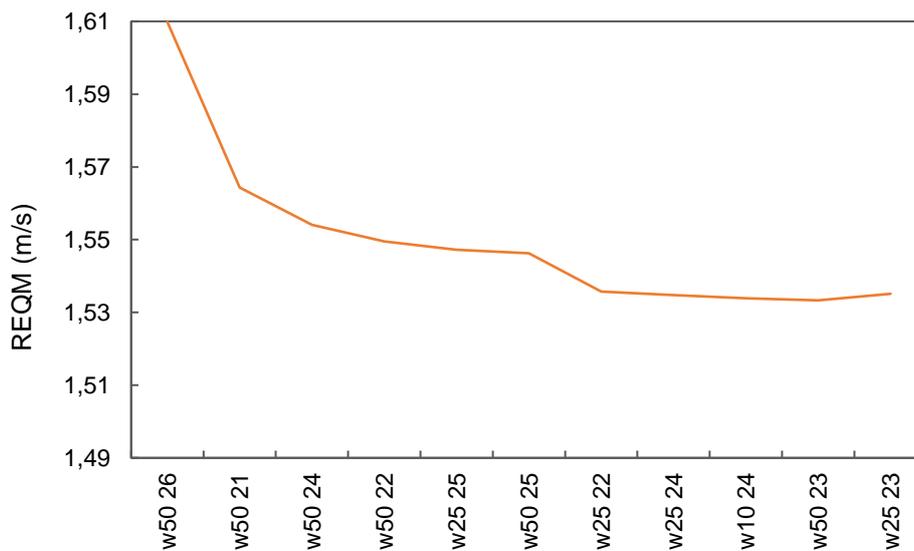


FIGURA 1.30 – RESULTADO DO TERCEIRO CICLO



1.2.5 HORIZONTE DE PREVISÃO DE 18 HORAS

Nas Figuras 1.31, 1.32 e 1.33 estão expressos os resultados do método *screening regression* dos três ciclos realizados para o horizonte de 18 horas à frente.

FIGURA 1.31 – RESULTADO DO PRIMEIRO CICLO.

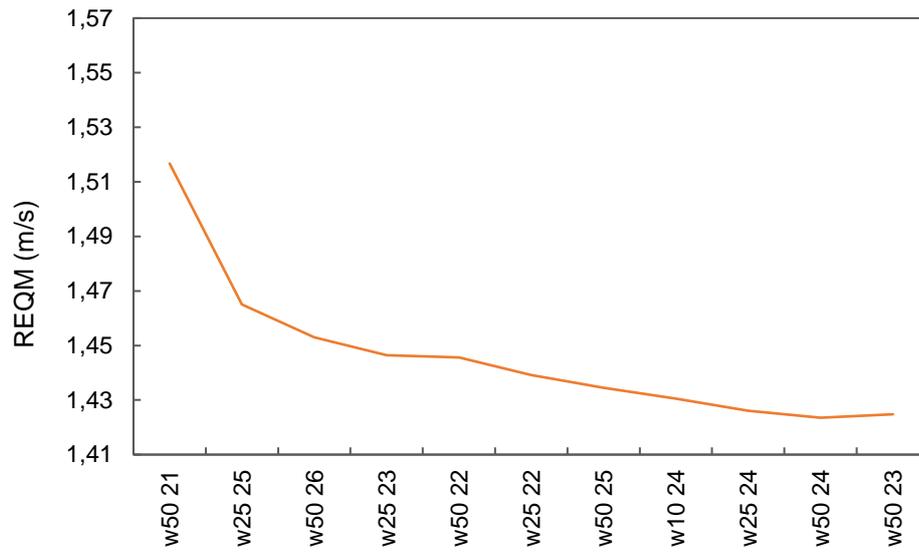


FIGURA 1.32 – RESULTADO DO SEGUNDO CICLO

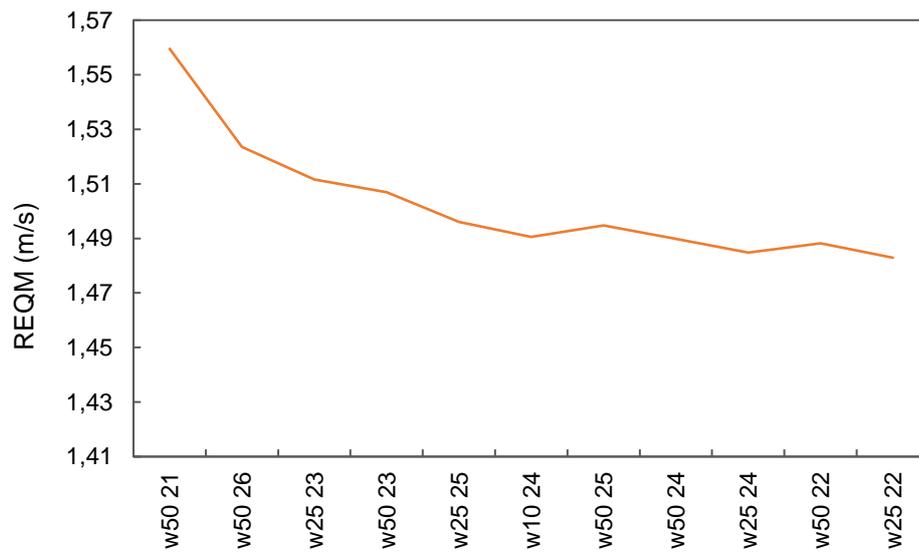
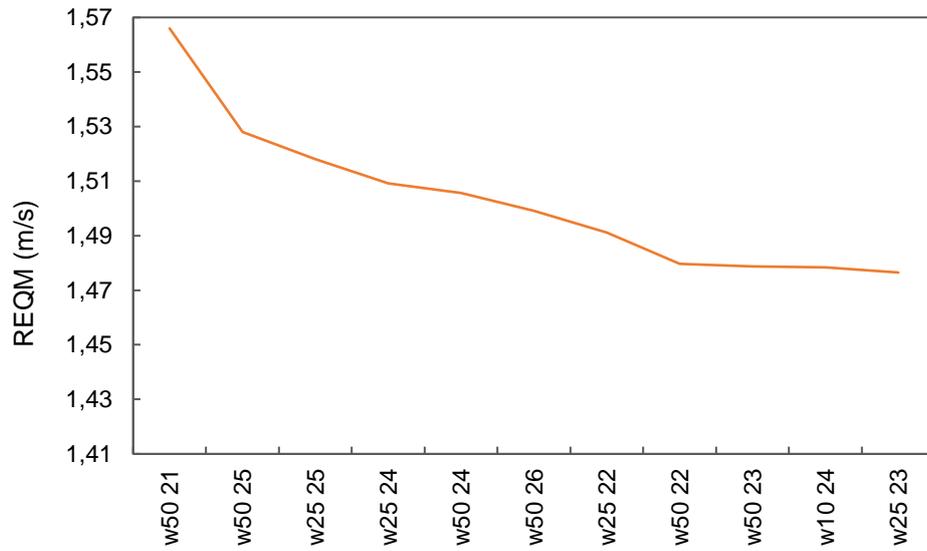


FIGURA 1.33 – RESULTADO DO TERCEIRO CICLO



1.2.6 HORIZONTE DE PREVISÃO DE 24 HORAS

Nas Figuras 1.34, 1.35 e 1.36 estão expressos os resultados do método *screening regression* dos três ciclos realizados para o horizonte de 24 horas à frente.

FIGURA 1.34 – RESULTADO DO PRIMEIRO CICLO.

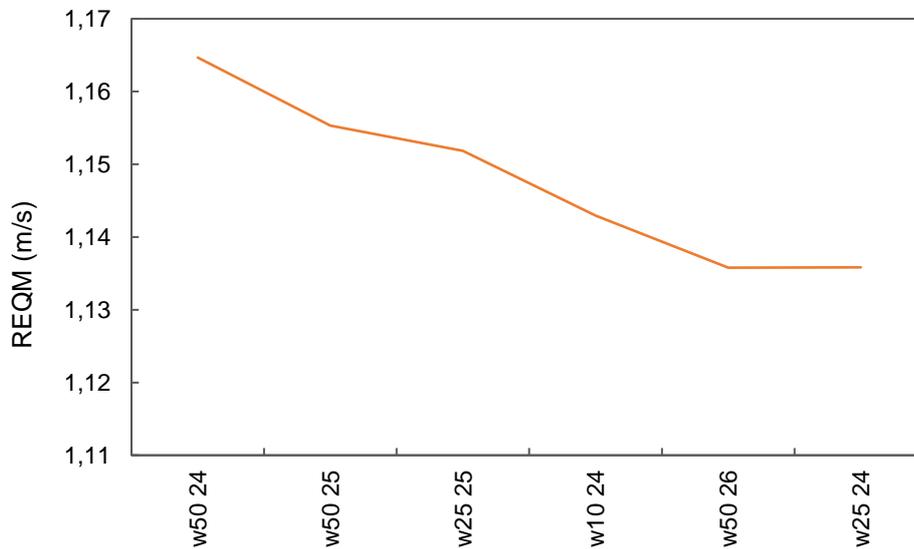


FIGURA 1.35 – RESULTADO DO SEGUNDO CICLO

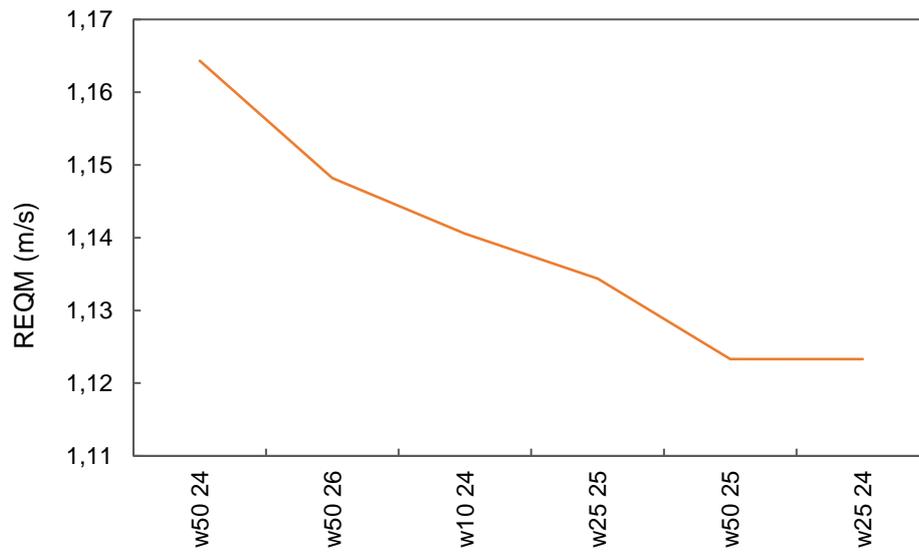


FIGURA 1.36 – RESULTADO DO TERCEIRO CICLO

