

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS DE ENERGIA

FELIPE MAIA BARBOSA OLIVEIRA

**PREVISÃO DA VELOCIDADE DO VENTO UTILIZANDO REDES
NEURAS ARTIFICIAIS E MODELOS AUTORREGRESSIVOS**

DISSERTAÇÃO

CURITIBA

2020

FELIPE MAIA BARBOSA OLIVEIRA

**PREVISÃO DA VELOCIDADE DO VENTO UTILIZANDO REDES
NEURAS ARTIFICIAIS E MODELOS AUTORREGRESSIVOS**

**Wind Speed Forecasting Using Artificial Neural Networks and
Autoregressive Models**

Dissertação apresentada ao Programa de Pós-graduação em Sistemas de Energia da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do título de “Mestre em Engenharia Elétrica” – Área de Concentração: Automação e Sistemas de Energia.

Orientador: Prof. Dr. Guilherme Santi Peron

Coorientador: Prof. Dr. Elder Oroski

CURITIBA

2020



Esta licença permite que outros façam download dos trabalhos e os compartilhem desde que atribuam crédito aos autores, mas sem que possam alterá-los de nenhuma forma ou utilizá-los para fins comerciais.



FELIPE MAIA BARBOSA OLIVEIRA

**PREVISÃO DA VELOCIDADE DO VENTO UTILIZANDO REDES NEURASIS ARTIFICIAIS E MODELOS
AUTORREGRESSIVOS**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Automação E Sistemas De Energia.

Data de aprovação: 26 de Novembro de 2020

Prof Guilherme De Santi Peron, Doutorado - Universidade Tecnológica Federal do Paraná

Prof.a Beatriz Dos Santos Pes, Doutorado - Instituto Federal de Educação, Ciência e Tecnologia do Paraná (Ifpr)

Prof Guilherme Luiz Moritz, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 26/11/2020.

AGRADECIMENTOS

A presente dissertação de mestrado só foi possível de ser feita graças ao precioso apoio de várias pessoas. Em primeiro lugar, não posso deixar de agradecer a minha família, fundamental de diversas maneiras no apoio prestado para que eu pudesse realizar este trabalho. Agradeço ao meu orientador, Professor Doutor Guilherme Santi Peron, por toda a paciência, empenho e sentido prático na orientação deste trabalho e nos artigos publicados. Também deixo meu agradecimento aos coorientadores que contribuíram para a elaboração deste trabalho, Professor Doutor Elder Oroski e Professor Doutor Ohara Kerusauskas Rayel. Por fim, agradeço à COPEL (Companhia Paranaense de Energia Elétrica) pelo apoio e incentivo no Projeto de Pesquisa PD ANEEL 2866-0464 / 2017 (Metodologia para Análise, Monitoramento e Gestão de GD por Fontes Incentivadas).

RESUMO

OLIVEIRA, Felipe. **Previsão da Velocidade do Vento Utilizando Redes Neurais Artificiais e Modelos Autorregressivos**. 2020. 73 f. Dissertação (Mestrado em Sistemas de Energia) – Universidade Tecnológica Federal do Paraná, Curitiba, 2020.

Os benefícios econômicos e ambientais da geração de energia elétrica pelo vento fizeram com que a energia eólica se tornasse uma das fontes mais promissoras para a geração de energia elétrica no Brasil. No entanto, a incerteza associada aos dados do vento, matéria prima desta fonte de geração, geralmente não pode ser desprezada. Assim, os dados devem ser avaliados com precisão para reduzir efetivamente os riscos da geração eólica nas operações do sistema de energia, portanto motiva o desenvolvimento de técnicas de previsão que tiram proveito de medições quase em tempo real, coletadas de instrumentos distribuídos geograficamente. Nessa abordagem, são comparados métodos de previsão, baseados em redes neurais artificiais e modelos autorregressivos lineares visando o horizonte de curtíssimo prazo. Uma nova abordagem está sendo proposta neste trabalho, um modelo autorregressivo linear e uma rede neural artificial para a previsão probabilística da amplitude do vento no período de curtíssimo prazo. A abordagem do conjunto proposto foi extensivamente avaliada, usando dados reais de cinco estações anemométricas instaladas na região metropolitana de Curitiba. Os resultados demonstram que as incertezas nos dados do vento podem ser previstas de forma confiável e que um desempenho competitivo é obtido.

Palavras-chave: Previsão da Velocidade do Vento, Rede Neural Artificial, Modelo Autorregressivo, Energia Eólica

ABSTRACT

OLIVEIRA, Felipe. **Wind Speed Forecasting Using Artificial Neural Networks and Autoregressive Models**. 2020. 73 f. Dissertação (Mestrado em Sistemas de Energia) – Universidade Tecnológica Federal do Paraná, Curitiba, 2020.

The economic and environmental benefits of wind power generation made wind energy one of the most promising sources for electric power generation in Brazil. However, the uncertainty associated with wind data, the source of this generation, generally cannot be overlooked. Thus, the data must be accurately evaluated to effectively reduce the risks of wind generation in energy system operations, therefore it motivates the development of forecasting techniques that take advantage of measurements in almost real time, collected from geographically distributed instruments. In this approach, forecasting methods, based on artificial neural networks and linear autoregressive models are compared, aiming at the very short term horizon. A new approach is being proposed in this work, a linear autoregressive model and an artificial neural network for the probabilistic forecast of wind speed in the very short term. The proposed set approach was extensively evaluated, using real data from five anemometric stations installed in the metropolitan region of Curitiba. The results demonstrate that the uncertainties in the wind data can be reliably predicted and that a competitive performance is obtained.

Keywords: Wind Speed Forecast, Artificial Neural Network, Autoregressive Model, Wind Energy

LISTA DE FIGURAS

Figura 1	– Matriz Elétrica Brasileira (EPE, 2017).	14
Figura 2	– Comparativo entre Geração Hidrelétrica e Eólica no ano de 2014 (EPE, 2017).	15
Figura 3	– Esquemático Modelo Estatístico.	21
Figura 4	– Esquemático Modelo Físico.	23
Figura 5	– Modelos Propostos.	34
Figura 6	– Torres Anemométricas instaladas na região metropolitana de Curitiba.	35
Figura 7	– Torre instalada no campus Neville da UTFPR.	36
Figura 8	– Modelo de Previsão por Redes Neurais Artificiais.	37
Figura 9	– Modelo NAR-RNA com entradas t na camada oculta composta por neurônios +, sendo que os pesos (W) e <i>bias</i> (b) são aplicados na função tangente hiperbólica, com um dado de saída passando pela camada de saída composta de uma função linear pura.	38
Figura 10	– Modelo NARX-RNA com entradas n na camada oculta composta por neurônios p , sendo que os pesos (w) e <i>bias</i> (b) são aplicados na função tangente hiperbólica, com um dado de saída passando pela camada de saída composta de uma função linear pura.	39
Figura 11	– Modelo de Previsão Autorregressivo Linear.	39
Figura 12	– Distribuição de Weibull e Rosa dos Ventos da Torre 1	42
Figura 13	– Distribuição de Weibull e Rosa dos Ventos da Torre 2	43
Figura 14	– Distribuição de Weibull e Rosa dos Ventos da Torre 3	44
Figura 15	– Distribuição de Weibull e Rosa dos Ventos da Torre 4	45
Figura 16	– Distribuição de Weibull da Torre 5	46
Figura 17	– Torre 1: Correlação cruzada da velocidade do vento com as entradas exógenas.	47
Figura 18	– Torre 1: Correlação cruzada entre as entradas exógenas.	47
Figura 19	– Torre 1: Rede Neural Artificial com 5 dados de entrada e 10 neurônios na camada oculta (NAR 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	49
Figura 20	– Torre 2: Rede Neural Artificial com 5 dados de entrada e 10 neurônios na camada oculta (NAR 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	49
Figura 21	– Torre 3: Rede Neural Artificial com 5 dados de entrada e 10 neurônios na camada oculta (NAR 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	50
Figura 22	– Torre 4: Rede Neural Artificial com 5 dados de entrada e 10 neurônios na camada oculta (NAR 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	50
Figura 23	– Torre 5: Rede Neural Artificial com 5 dados de entrada e 10 neurônios na camada oculta (NAR 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	51
Figura 24	– Torre 1: Rede Neural Artificial com 5 dados de entrada, 10 neurônios	

	na camada oculta e temperatura como entrada exógena (NARX3 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	52
Figura 25 – Torre 2:	Rede Neural Artificial com 5 dados de entrada, 10 neurônios na camada oculta e temperatura como entrada exógena (NARX3 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	52
Figura 26 – Torre 3:	Rede Neural Artificial com 5 dados de entrada, 10 neurônios na camada oculta e temperatura como entrada exógena (NARX3 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	53
Figura 27 – Torre 4:	Rede Neural Artificial com 5 dados de entrada, 10 neurônios na camada oculta e temperatura como entrada exógena (NARX3 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	53
Figura 28 – Torre 5:	Rede Neural Artificial com 5 dados de entrada, 10 neurônios na camada oculta e temperatura como entrada exógena (NARX3 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	54
Figura 29 – Torre 1:	Modelo autorregressivo linear com 5 dados de entrada e fator de esquecimento um (AR 5dl1). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	55
Figura 30 – Torre 2:	Modelo autorregressivo linear com 5 dados de entrada e fator de esquecimento um (AR 5dl1). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	55
Figura 31 – Torre 3:	Modelo autorregressivo linear com 5 dados de entrada e fator de esquecimento um (AR 5dl1). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	56
Figura 32 – Torre 4:	Modelo autorregressivo linear com 5 dados de entrada e fator de esquecimento um (AR 5dl1). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	56
Figura 33 – Torre 5:	Modelo autorregressivo linear com 5 dados de entrada e fator de esquecimento um (AR 5dl1). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	57
Figura 34 – Torre 1:	Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	58
Figura 35 – Torre 2:	Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	58
Figura 36 – Torre 3:	Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	59
Figura 37 – Torre 4:	Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção	

	do vento (ARX1 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	59
Figura 38 –	Torre 5: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	60
Figura 39 –	Torre 1: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9 30min). Dados de velocidade do vento de uma semana (1000) previstos a cada trinta minutos.	61
Figura 40 –	Torre 2: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9 30min). Dados de velocidade do vento de uma semana (1000) previstos a cada trinta minutos.	61
Figura 41 –	Torre 3: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9 30min). Dados de velocidade do vento de uma semana (1000) previstos a cada trinta minutos.	62
Figura 42 –	Torre 4: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9 30min). Dados de velocidade do vento de uma semana (1000) previstos a cada trinta minutos.	62
Figura 43 –	Torre 5: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9 30min). Dados de velocidade do vento de uma semana (1000) previstos a cada trinta minutos.	63
Figura 44 –	Torre 1: Modelo autorregressivo linear FRS com 5 dados de entrada, fator de esquecimento 0,9, média móvel e entrada exógena de temperatura (ARMAX2 5dl0,9). Dados de velocidade do vento de uma semana (1.000) previstos a cada dez minutos.	64
Figura 45 –	Torre 2: Modelo autorregressivo linear FRS com 5 dados de entrada, fator de esquecimento 0,9, média móvel e entrada exógena de temperatura (ARMAX2 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	64
Figura 46 –	Torre 3: Modelo autorregressivo linear FRS com 5 dados de entrada, fator de esquecimento 0,9, média móvel e entrada exógena de temperatura (ARMAX2 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	65
Figura 47 –	Torre 4: Modelo autorregressivo linear FRS com 5 dados de entrada, fator de esquecimento 0,9, média móvel e entrada exógena de temperatura (ARMAX2 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	65
Figura 48 –	Torre 5: Modelo autorregressivo linear FRS com 5 dados de entrada, fator de esquecimento 0,9, média móvel e entrada exógena de temperatura (ARMAX2 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.	66

LISTA DE TABELAS

Tabela 1	–	Resumo dos dados medidos nas torres anemométricas instaladas na RMC.	41
Tabela 2	–	Correlação cruzada média entre velocidade do vento e entradas exógenas	48
Tabela 3	–	Correlação cruzada média entre entradas exógenas	48
Tabela 4	–	Resultados RMSE	67
Tabela 5	–	Resultados R^2	68

LISTA DE SIGLAS

AMA	<i>Acompanhamento de Medições Anemométricas</i>
AR	<i>Modelo Autorregressivo Linear</i>
ARIMA	<i>Modelo Autorregressivo Linear de Médias Móveis, do inglês, Autoregressive integrated moving average</i>
ARMA	<i>Modelo Autorregressivo de Média Móvel</i>
ARMAX	<i>Modelo Autorregressivo de Média Móvel com entrada Exógena</i>
ARX	<i>Modelo Autorregressivo Linear com Entrada Exógena.</i>
CFD	<i>Dinâmica dos Fluidos Computacional, do inglês Computational Fluid Dynamics</i>
COPEL	<i>Companhia Paranaense de Energia</i>
FRS	<i>Free Run Simulation, do inglês, Simulação Livre</i>
KSA	<i>k Steap Ahead, do inglês k Passos a Frente</i>
MA	<i>Média móvel, do inglês Moving Average</i>
MLP	<i>Multi Layer Perceptron</i>
NAR	<i>Modelo Autorregressivo Não Linear</i>
NARX	<i>Modelo Autorregressivo Não Linear com Entradas Exógenas, do inglês Nonlinear Autoregressive eXogenous Model</i>
NWP	<i>Dinâmica dos Fluidos Computacional, do inglês Numerical Weather Prediction</i>
ONS	<i>Operador Nacional do Sistema Elétrico</i>
OSA	<i>One Steap Ahead, do inglês Um Passo a Frente</i>
PROINFA	<i>Programa de Incentivo às Fontes Alternativas de Energia Elétrica</i>
RMSE	<i>Raiz do Erro Médio Quadrático, do inglês Root Mean Square Error</i>
RNA	<i>Rede Neural Artificial</i>
SCADA	<i>Controle de Supervisão e Aquisição de Dados, do inglês Supervisory Control and Data Acquisition</i>
SIN	<i>Sistema Interligado Nacional</i>
X	<i>Entrada Exógena</i>

LISTA DE SÍMBOLOS

δ_t	Instante de tempo
$y(t)$	saída do modelo de previsão RNA
g_i	função não linear da RNA
n	número de camadas ocultas na RNA
$f_j(\mathbf{x}; \mathbf{w})$	funções de entrada de dados da velocidade do vento e do peso aplicado ao neurônio da RNA
p	número de neurônios na camada oculta da RNA
\circ	operação de composição da RNA
\mathbf{w}	parâmetro do peso aplicado a RNA
b	erro de aproximação das séries
$\tanh(x)$	tangente hiperbólica
$r(\cdot)$	função definida pelo treinamento da RNA por meio da otimização dos pesos
$y(k)$	saída do modelo autorregressivo
$\phi^T(k-1)$	vetor de regressores transposto do modelo autorregressivo
$\hat{\Theta}_k$	vetor de parâmetros estimado
k	iteração
$\varepsilon(k)$	erro entre o valor previsto e valor real
$\hat{\Theta}_k$	estimador recursivo
$\hat{\Theta}_{k-1}$	vetor de regressores
$E[\cdot]$	Esperança matemática
$\eta(k)$	parcela de inovação
$\phi(k-1)$	vetor de parâmetros
$\hat{\phi}(k-1)$	vetor de parâmetros com dados conhecidos
P_k	matriz de covariância
λ	fator de esquecimento
$x(k-1)$	entrada exógena
$\xi(k)$	média móvel
R^2	<i>Coefficiente de Correlação Linear</i>
V_m	velocidade do vento medido
V_p	velocidade do vento previsto
$X_{1,t=0}^{\infty}$	Série temporal 1
$X_{2,t=0}^{\infty}$	Série temporal 2
$\gamma_{1,2}(h)$	Covariância cruzada
$\rho_{1,2}(h)$	correlação cruzada
$(x_i(t))$	entradas exógenas

SUMÁRIO

1 INTRODUÇÃO	13
1.1 MOTIVAÇÃO	17
1.2 OBJETIVOS	18
1.2.1 Objetivo Geral	18
1.2.2 Objetivos Específicos	18
2 MODELOS DE PREVISÃO DE GERAÇÃO EÓLICA	20
2.1 MODELOS ESTATÍSTICOS	21
2.2 MODELOS FÍSICOS	22
2.3 MODELOS APLICADOS	24
2.3.1 Rede Neural Artificial	24
2.3.2 Modelo Autorregressivo Linear	27
2.4 MODELO DE AVALIAÇÃO DO DESEMPENHO DOS MODELOS DE PREVISÃO	31
2.5 ANÁLISE DE CORRELAÇÃO CRUZADA PARA ENTRADAS EXÓGENAS	32
3 METODOLOGIA	33
3.1 COLETA DE DADOS E PRÉ PROCESSAMENTO	34
3.2 MODELO RNA	36
3.3 MODELO DE PREVISÃO AUTORREGRESSIVO LINEAR	38
3.4 SELEÇÃO DO MODELO DE PREVISÃO	40
4 RESULTADOS	41
4.1 MODELO RNA	48
4.2 MODELO DE PREVISÃO AUTORREGRESSIVO LINEAR	54
4.3 ANÁLISE DOS RESULTADOS	66
5 CONCLUSÃO	69
REFERÊNCIAS	70

1 INTRODUÇÃO

Recentemente a matriz elétrica brasileira passou por uma diversificação nas suas fontes de geração de energia elétrica, uma vez que até o início do século XXI, acima de 80% da geração elétrica no Brasil provinha de fonte hidrelétrica, enquanto atualmente o percentual é de aproximadamente 66% (EPE, 2017). Uma das principais motivações desta decisão é a ausência de grandes potenciais hidrelétricos sem impedimento ambiental, o que acarreta em uma redução da dependência existente às condições hidrológicas dos rios brasileiros. Desta forma, o sistema elétrico brasileiro buscou novas fontes de energia, principalmente da termelétricas, a qual é uma das mais caras e polui o ambiente.

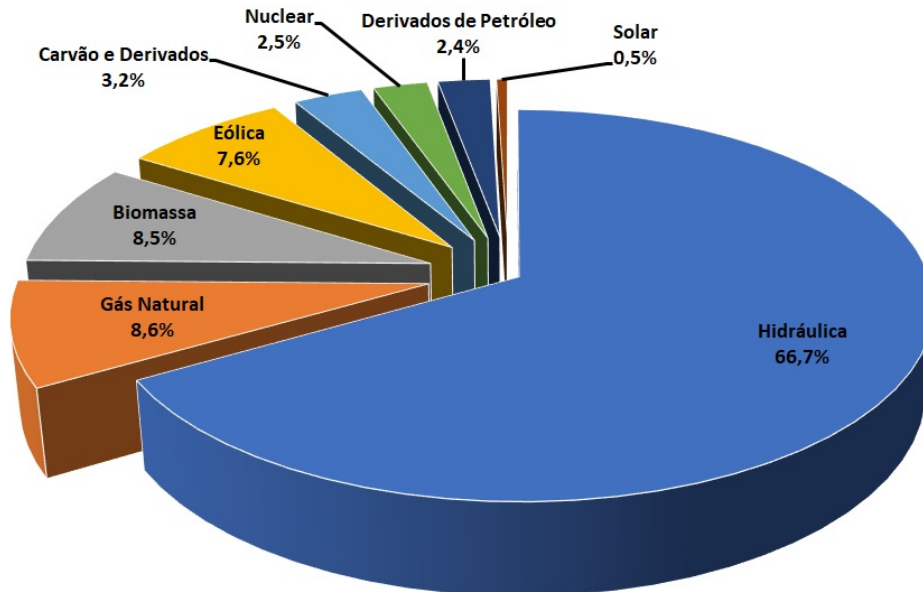
Buscando alternativas para um crescimento sustentável, para minimizar o impacto ambiental da geração de energia elétrica, o Brasil incentivou a busca por novas fontes de energia, com apoio governamental através de programas como o Programa de Incentivo às Fontes Alternativas de Energia Elétrica (PROINFA). Neste contexto, a energia eólica surgiu como uma alternativa renovável promissora, por ser considerada uma fonte de energia de baixo impacto ambiental, além de permitir a utilização conectada ao Sistema Interligado Nacional (SIN) ou em locais remotos, com extração em terra e no mar e, ainda, poder dividir o local de sua instalação com atividades agropecuárias (ABEOLICA, 2018).

Tem-se observado o crescimento da energia eólica na matriz energética mundial em que a perspectiva é positiva para as próximas décadas (GWEC, 2017). O crescimento ocorreu pelo avanço da tecnologia que possibilitou a redução do custo da eletricidade produzida e devido às metas, a nível mundial, para a redução da emissão do CO₂. Assim, pode-se observar o crescimento da Energia Eólica na matriz energética brasileira, passando de 245,6 MW em 2007 para 12767 MW em 2017 (ABEOLICA, 2018), como ilustra a Figura 1.

A redução da emissão do CO₂ devido à substituição de outro tipo de geração pela geração eólica no Brasil em 2017 foi de 20,97 milhões de toneladas de CO₂, o equivalente à emissão anual de cerca de 16 milhões de automóveis (ABEOLICA, 2018). Em razão do cenário favorável para a geração eólica, em 2017 o Brasil ultrapassou o Canadá no Ranking Mundial de capacidade instalada de energia eólica e agora ocupa a oitava posição, enquanto em 2012, o Brasil estava na décima quinta colocação (GWEC, 2017).

Além do baixo custo comparado às demais fontes energéticas e baixo impacto

Figura 1 – Matriz Elétrica Brasileira (EPE, 2017).




Fonte: Adaptado de (EPE, 2017).

ambiental, a energia eólica é considerada estratégica para a matriz energética brasileira. Para a região Nordeste, durante a época do ano em que o Brasil tem a maior velocidade do vento, coincide-se com a estação seca em que os reservatórios das grandes usinas hidrelétricas estão em níveis mais baixos, conforme pode ser visto na Figura 2 (DUTRA; SZKLO, 2008).

Para a geração eólica, são necessários ventos com as características estáveis, com intensidade certa e sem mudanças bruscas de velocidade ou de direção (PINTO, 2013). No Atlas Eólico Brasileiro (AMARANTE et al., 2001) é visto que o Brasil é bem provido nestes quesitos, principalmente no Nordeste, o que explica em grande medida o sucesso da energia eólica no Brasil nos últimos anos.

O vento se origina do deslocamento de ar no sentido horizontal, oriundos da diferença de gradientes de pressão (PINTO, 2013), variação espacial e temporal do balanço de energia na superfície terrestre e pressão atmosférica, ou seja, o vento se desloca de áreas de maior pressão (regiões quentes) para áreas de menor pressão (regiões frias). A distribuição dos ventos no Brasil é realizada pelas características da circulação planetária da atmosfera próxima. Os sistemas de alta pressão Anticiclone Subtropical do Atlântico

Figura 2 – Comparativo entre Geração Hidrelétrica e Eólica no ano de 2014 (EPE, 2017).



Fonte: Adaptado de (DUTRA; SZKLO, 2008).

Sul e do Atlântico Norte e a faixa de baixas pressões da Depressão Equatorial se destacam como os principais aspectos influenciadores (AMARANTE et al., 2001).

Com a crescente implantação de sistemas eólicos para a geração de energia elétrica no Brasil, surge a necessidade de uma previsão confiável dos dados anemométricos (WENDEL et al., 2017), visto que o impacto desta fonte de energia no SIN se torna cada vez mais relevante. A previsão confiável dos dados do vento a curto e curtíssimo prazo é fundamental para a previsão do potencial de geração de parques eólicos, uma vez que estas informações são utilizadas no planejamento da operação do sistema elétrico. Os dados do vento possuem certo grau de incerteza associada à dinâmica da atmosfera, ou seja, à circulação das camadas de ar provocada pelo aquecimento desigual do planeta (PINTO, 2013), o que acaba dificultando a previsão da velocidade de vento.

Os métodos utilizados para a previsão anemométrica são de predição (ZHAO et al., 2016). Estes são usados como preditores e incluem principalmente os métodos físicos, métodos convencionais de aprendizado de máquina e métodos de aprendizagem profunda, do inglês *Deep Learning*, método baseado em um grupo de algoritmos que modelam abstrações de alto nível de dados, usando um conjunto de dados com camadas de processamento, compostas por transformações lineares e não lineares (GOODFELLOW et al., 2016). Também existem os métodos de otimização, apesar de não serem responsáveis pela predição, são usados para melhorar o desempenho dos preditores,

contendo principalmente métodos de processamento de sinais e métodos de otimização de parâmetros (ZHAO et al., 2016).

Os métodos físicos são usados principalmente para previsão de médio e longo prazo e são baseados nas tecnologias de Previsão Numérica do Tempo, do inglês *Numerical Weather Prediction* (NWP) e Dinâmica dos Fluidos Computacional, do inglês *Computational Fluid Dynamics* (CFD) (WANG et al., 2017). A previsão dos dados do vento é obtida usando parâmetros físicos como a temperatura ambiente, pressão atmosférica e condições do terreno (GONZÁLEZ-APARICIO et al., 2017). Métodos de modelagem física tentam estabelecer um modelo matemático preciso para a previsão de dados do vento usando informações geográficas e meteorológicas. No entanto, esse tipo de abordagem pode não ser aplicável a tarefas práticas de previsão em tempo real devido ao alto custo computacional envolvido (ZHAO et al., 2016).

Os modelos estatísticos podem desenvolver uma ótima relação entre a previsão de geração eólica e amostras históricas, um exemplo disso é o Modelo Autorregressivo Linear de Médias Móveis (ARIMA) utilizado por Camelo et al. (2017) para prever a velocidade do vento em um horizonte de alcance de curtíssimo prazo, em que os resultados apresentaram a Raiz do Erro Médio Quadrático, do inglês *Root Mean Square Error* (RMSE) de 0,71m/s para a velocidade do vento na cidade de Fortaleza, que representa um erro percentual médio menor que 10%.

A rede neural artificial (RNA) é outra técnica de inteligência computacional aplicável na predição da velocidade do vento em um horizonte de curto prazo que se tornou atraente nos últimos 20 anos (WANG et al., 2011). As RNAs foram inspiradas de forma conceitual no cérebro humano, referenciando alguns aspectos do neurônio biológico (HAYKIN, 2001), ou seja, habilidade de aprender em um ambiente, podendo evoluir com a experiência, realizando generalizações com base em seu conhecimento acumulado anteriormente. Além disso, podem ser compostas de modelos não-lineares e lineares, permitindo encontrar melhores resultados quando comparadas com outros modelos de previsão (ZHANG, 2003).

A RNA é uma técnica promissora em uma variedade de assuntos, incluindo reconhecimento de padrões, previsão de séries temporais e, portanto, tem sido amplamente usada para previsão de dados de vento. Várias arquiteturas de RNA foram propostas na literatura para prever dados de vento (JUNG; BROADWATER, 2014; KAUR et al., 2016; CHANG et al., 2017; DOUCOURE et al., 2016; LYDIA et al., 2016; HIRUMA, 2016; LIU et al., 2018b). O modelo proposto por Hiruma (2016) realizou a predição de dados

de vento por RNA, possuindo a característica de Perceptron Multi Camada, do inglês *Multi Layer Perceptron* (MLP), com o algoritmo de treinamento de retropropagação, do inglês *backpropagation*, para o parque eólico instalado na cidade de Palmas, Paraná, sul do Brasil, onde os melhores resultados foram obtidos com a RNA em comparação com outros modelos lineares de previsão. O método de previsão de vento apresentado por Liu et al. (2018) realiza a decomposição por *wavelet* para remover componentes de ruído que são adicionados aos dados de vento pelos sensores. Os dados filtrados são posteriormente utilizados em uma RNA convolucional. Esta RNA usa uma variação de perceptrons multicamada desenvolvidos de modo a demandar o mínimo pré-processamento possível. Em Jung et al. (2014), várias técnicas de previsão foram comparadas através de métricas e bancos de dados propostos, sendo demonstrado que cada método pode fornecer melhor desempenho para diferentes horizontes de tempo. Além disso, os resultados mostram uma dependência relacionada à localização da estação de medição. O trabalho de Kaur et al. (2016) desenvolveu cinco modelos diferentes de RNA. O melhor modelo para previsão de velocidade do vento a curto prazo tem 19 camadas ocultas, 4 entradas e 1 saída.

Outro modelo de previsões de séries temporais que merece destaque devido à sua importância e utilidade é o modelo Autoregressivo Integrativo com Média Móvel (ARIMA). Este tipo de modelo é muito popular por causa de suas propriedades estatísticas, utilizado por Camelo et al. (2015) para previsão da amplitude da velocidade do vento de algumas regiões do Nordeste Brasileiro. Os modelos ARIMA são flexíveis, ou seja, permitem ajustes e adaptações em seus parâmetros, contribuindo para que diferentes tipos de séries temporais sejam representados, assumindo assim, uma estrutura que pode ter correlação linear entre os valores das séries temporais (HIRUMA, 2016).

Neste trabalho são propostos modelos de previsão de dados anemométricos utilizando RNA e modelos autorregressivos. Em primeiro lugar, foi realizada a coleta de dados e o seu pré-processamento; na sequência, a modelagem das RNAs e dos modelos autorregressivos lineares. Finalmente, a análise comparativa do desempenho entre os modelos.

1.1 MOTIVAÇÃO

A geração eólica é uma fonte de energia de difícil previsão, por apresentar grande variabilidade no curto e curtíssimo prazo, devido à forte dependência das condições meteorológicas. O desafio da operação do Sistema Interligado Nacional (SIN) em tempo real está na previsão da velocidade do vento, que é o dado de entrada para o cálculo da

energia eólica gerada em um determinado período.

Devido à importância da energia eólica na matriz elétrica brasileira, prever a geração de energia desta fonte é importante para evitar problemas na operação em tempo real, como o controle de tensão, carregamento de equipamentos e economicidade da operação. Desta forma, o desenvolvimento de modelo de previsão da velocidade do vento confiável para o horizonte de curto e curtíssimo prazo é fundamental para o planejamento energético.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Aplicar métodos de predição, como Redes Neurais Artificiais e modelos Autorregressivos, ao problema de previsão de amplitude da velocidade do vento em ambiente urbano.

1.2.2 Objetivos Específicos

- Estudar as características do vento;
- Estudar os modelos de previsão da velocidade do vento existentes;
- Coletar e tratar os dados anemométricos;
- Aplicar um modelo para previsão de dados anemométricos através de RNAs;
- Aplicar um modelo para previsão de dados anemométricos através de modelos autorregressivos;
- Validar os modelos diante de novos dados experimentais;
- Comparar os resultados encontrados nos modelos de previsão desenvolvidos.

Esse trabalho está organizado em cinco capítulos, incluindo a introdução que está neste capítulo. No Capítulo 2, apresenta-se a fundamentação teórica sobre modelos de previsão de geração eólico, com enfoque nas Redes Neurais Artificiais e Modelos Autorregressivos Lineares. O Capítulo 3 descreve a metodologia dos modelos de previsão desenvolvidos neste trabalho. O Capítulo 4 demonstra os dados utilizados para a

realização do trabalho e os resultados obtidos para os modelos desenvolvidos. No Capítulo 5, são expostas as conclusões e as recomendações para futuros trabalhos.

2 MODELOS DE PREVISÃO DE GERAÇÃO EÓLICA

Os modelos de previsão de vento melhoram a confiança das previsões de geração eólica, diminuem riscos financeiros e agregam valor à operação através da melhor alocação das manutenções das turbinas eólicas. A previsão da velocidade do vento é um indicador importante na gestão da manutenção e planejamento operacional de parques eólicos, podendo prever de minutos até meses à frente. Neste trabalho serão aplicados modelos com redes neurais artificiais e modelos autorregressivos para o horizonte de curtíssimo prazo, em que é previsto a velocidade do vento de alguns segundos a trinta minutos a frente.

A velocidade do vento altamente variável no espaço e no tempo. Este é um dos grandes desafios impostos pela energia eólica, pois a velocidade do vento está diretamente relacionada com a capacidade de produção de energia de uma turbina eólica. Desta forma, prever a potência elétrica disponível em um momento futuro de forma consistente é importante para a operação de um parque eólico. A previsão da geração eólica é fundamental para o despacho de energia¹ pelo órgão operador do sistema elétrico. Pode-se interpretar o desafio de conseguir alta aderência dos dados estimados aos dados reais, que são utilizados como referência para previsão de despacho de energia (GONÇALVES et al., 2010). No Brasil a operação do SIN é realizada pelo Operador Nacional do Sistema Elétrico (ONS).

A previsão de potência eólica disponível está intimamente relacionada à previsão do vento próximo à superfície, tratando-se portanto de objeto de estudo das ciências atmosféricas (PINTO, 2013).

A previsão de vento para a geração eólica está atraindo a comunidade de pesquisa em todo o mundo, com o objetivo de obter modelos mais precisos, que podem ser classificados em quatro tipos, de acordo com os horizontes temporais (LIU et al., 2018a):

- Previsão de curtíssimo prazo: de alguns segundos a trinta minutos a frente. Sua principal aplicação é para previsão de geração de energia, análise de mercado de energia e ações regulatórias;
- Previsão de curto prazo: de trinta minutos a seis horas a frente. O principal objetivo é prever a energia gerada pelas turbinas eólicas;


¹Energia gerada por uma ou mais usinas do SIN, alocada pelo órgão de coordenação da geração (ONS).

- Previsão de médio prazo: de seis horas a um dia a frente. O principal objetivo é a decisão de ligar ou desligar as turbinas eólicas, visando à segurança operacional;
- Previsão de longo prazo: de 1 dia a 1 semana a frente. Esta abordagem é usada principalmente para decisões de geração de energia e programação de manutenção.

2.1 MODELOS ESTATÍSTICOS

Os modelos estatísticos², normalmente aplicados em previsões de curtíssimo prazo, utilizam dados históricos da velocidade do vento, registrados pelos anemômetros instalados nos aerogeradores ou nas torres de Acompanhamento de Medição Anemométricas (AMA), em que o instrumento instalado pode comunicar os dados pelo sistema de controle e monitoramento da usina eólica conhecido como Controle de Supervisão e Aquisição de Dados, do inglês *Supervisory Control and Data Acquisition* (SCADA), conforme a Figura 3 (WANG et al., 2011).

Figura 3 – Esquemático Modelo Estatístico.



Fonte: Adaptado de (HIRUMA, 2016).

Por basearem-se em dados medidos em instantes anteriores ao horizonte de previsão, os modelos estatísticos geram resultados mais aderentes à realidade que os modelos de persistência (WHEELWRIGHT et al., 1998). Esta técnica consiste em assumir que as condições que influenciam a previsão não mudarão em um intervalo δ_t , fazendo com que, por exemplo, a velocidade nesse instante t seja igual à atual (HIRUMA, 2016).

²Modelo estatístico é um conjunto de hipóteses sobre dados observados e dados semelhantes de diferentes fatores. Descreve a relação entre dados aleatórios com outro conjunto de dados (não aleatórios).

Há uma grande variedade de métodos estatísticos, tais como: Modelo Autorregressivo de Média Móvel (ARMA) (CAMELO et al., 2015), Modelo ARIMA (HIRUMA, 2016), Filtro de Kalman (CAMELO, 2018) e Regressão Harmônica (CAMELO, 2017), assim como métodos envolvendo inteligência computacional, como as Redes Neurais Artificiais.

O modelo Autorregressivo Linear a parâmetros concentrados ³ não leva em conta as informações específicas do local que está instalado o parque eólico. Destaca-se, porém, que em modelos com entradas exógenas ⁴, informações como direção do vento incidente, umidade e temperatura são utilizadas com o intuito de melhorar os resultados. Neste caso, a utilização de entradas exógenas pode ser realizada pelo Modelo Autorregressivo de Média Móvel com entrada Exógena ARMAX, que é uma combinação de um processo Autorregressivo AR e médias móveis (MA, do *inglês Moving Average*), utilizando entradas exógenas X. Por exemplo, este modelo pode estimar a amplitude da velocidade do vento, utilizando como dados de entrada, para o modelo de previsão, informações específicas do local, como temperatura, umidade e direção do vento.

Baseando-se em séries de dados anteriores da amplitude da velocidade do vento, o modelo estatístico é eficiente para horizontes de previsão de até seis horas à frente do instante atual. Outro ponto positivo desta classe de modelos é referente à alta capacidade de processamento das previsões e necessidade de recursos computacionais simples, quando comparado aos modelos físicos (WANG et al., 2011).

2.2 MODELOS FÍSICOS

Os modelos físicos consideram diversas informações referentes às usinas eólicas para o NWP, como a posição geográfica dos aerogeradores, características do terreno, características técnicas do aerogerador, rugosidade e obstáculos. Este modelo normalmente é utilizado para horizonte de tempo de 6 a 72 horas a frente (WANG et al., 2011).

O NWP se concentra em realizar o processamento computacional dos dados atuais do clima para prever o seu estado futuro. As observações meteorológicas do presente são entradas para os modelos numéricos de computador através de um processo conhecido como assimilação de dados para produzir saídas de temperatura, precipitação e centenas

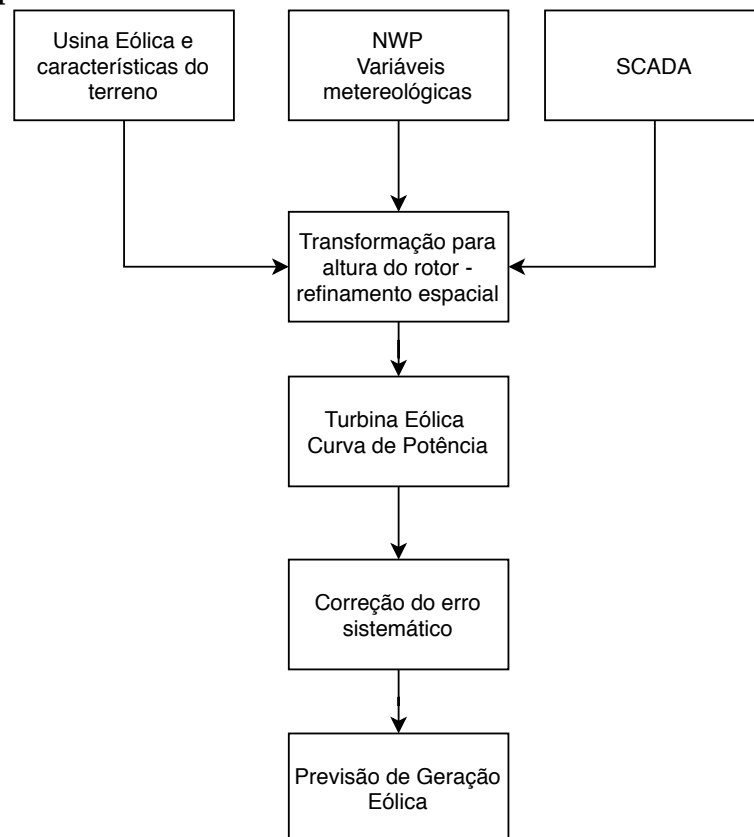
³simplifica comportamento de sistemas físicos distribuídos espacialmente

⁴dado externo a velocidade do vento, no caso deste trabalho, variáveis meteorológicas como temperatura, umidade e direção do vento.

de outros elementos meteorológicos, como a velocidade do vento (NOAA, 2020).

Os NWP são sensíveis às condições iniciais, visto que pequenos erros na previsão crescem rapidamente e afetam a previsibilidade. Isso pode ser contornado usando diferentes combinações de modelos que possuam múltiplos modelos NWP, ou outros modelos físicos com condições iniciais diferenciadas (SOUZA, 2015). Porém, os modelos NWP demandam um grande esforço computacional devido seu processamento utilizar uma grande quantidade de dados, como as condições do relevo e meteorológicas e, por este motivo, a sua utilização na previsão de curto prazo é bastante limitada. A Figura 4 demonstra o esquemático de um modelo físico, em que o passo de transformação para altura do rotor consiste em prever a velocidade do vento na altura do rotor da turbina, pois a curva de potência da turbina é calculada com a velocidade do vento nesta altura.

Figura 4 – Esquemático Modelo Físico.



Fonte: Adaptado de (HIRUMA, 2016).

Os modelos físicos realizam a previsão com as variáveis meteorológicas e leis da física, enquanto os modelos baseados apenas em dados históricos realizam uma previsão estatística. A fusão de ambos é possível, cujo modelo híbrido tem o intuito de obter o melhor de cada modelo, ou seja, combina a precisão das séries temporais para períodos

curtíssimos e curtos de tempo com a precisão dos modelos físicos para horizontes de período médio prazo. Neste caso, utiliza-se a previsão dos modelos estatísticos de curto e curtíssimo prazo, combinando com resultados precisos apresentados por modelos físicos para horizontes de médio e longo prazo (HIRUMA, 2016). Para este modelo híbrido deve-se avaliar individualmente aquele que melhor se adapta a cada situação. Neste trabalho o foco será dado em modelos de previsão estatísticos, por RNAs e modelos autorregressivos lineares.

2.3 MODELOS APLICADOS

Neste trabalho, estão sendo propostos uma rede neural artificial e alguns modelos autorregressivos lineares para a previsão probabilística da amplitude da velocidade do vento.

2.3.1 Rede Neural Artificial

As redes neurais artificiais são modelos inspirados pelo cérebro humano, capazes de uma aprendizagem de máquina e reconhecimento de padrões. RNAs são representadas por um conjunto de neurônios interconectados, que recebem dados de entrada e através de seu treinamento têm a capacidade natural de armazenar conhecimento e disponibilizá-lo para uso futuro, simulando o comportamento desejado de acordo com a saída desejada. As RNAs assemelham-se ao cérebro em dois aspectos, extraem conhecimento do ambiente através de um processo de aprendizagem ou treinamento e os pesos das conexões entre os neurônios armazenam o conhecimento (HAYKIN, 2001).

Uma RNA é definida como uma composição de funções não lineares da forma (TEALAB et al., 2017)

$$y(t) = g_1 \circ g_2 \cdots \circ g_n(f_1(\mathbf{x}; \mathbf{w}), f_2(\mathbf{x}; \mathbf{w}) \dots f_p(\mathbf{x}; \mathbf{w})), \quad (1)$$

em que o $y(t)$ indica a saída da rede neural artificial, g_i para $i = \{1, 2, \dots, n\}$ são funções não lineares, n é o número de camadas ocultas, $f_j(\mathbf{x}; \mathbf{w})$ para $j = \{1, 2, \dots, p\}$ são funções da entrada de dados da velocidade do vento e do peso aplicado no neurônio, com p indicando o número de neurônios nas camadas ocultas e o símbolo \circ entre funções indica a operação da composição. Esta operação pode ser descrita pelo exemplo em que dadas duas funções $f : A \rightarrow B$ e $g : B \rightarrow C$, denomina-se $h : A \rightarrow C$, tal que $h = (g \circ f(x)) = g(f(x))$.

Os parâmetros \mathbf{w} e b são descobertos na etapa de aprendizado a partir dos dados observados das séries temporais de velocidade do vento. Os pesos iniciais \mathbf{w} podem assumir valores aleatórios, que por sua vez serão atualizados usando os dados observados como referência na RNA.

As RNAs podem ser usadas para várias aplicações, incluindo modelos de previsão. Diferentes tipos de modelos de RNA podem resolver um problema e a escolha do modelo mais adequado depende de vários parâmetros, como a complexidade da função não linear⁵, a arquitetura, o algoritmo de treinamento⁶, o número de neurônios e o número de casos de treinamento (VARSHNEY; PODDAR, 2011). Dentre os vários tipos de RNA, optou-se pelo modelo autorregressivo não linear (NAR)⁷, pois esse modelo obtém melhores resultados quando comparado a outros modelos de RNA conforme a literatura (TEALAB et al., 2017).

Existem diversas topologias⁷ e algoritmos de aprendizagem de RNAs. Para a correta estrutura da RNA deve ser selecionado: o tipo de neurônio, o número de parâmetros de entrada, o número de camadas ocultas (intermediárias) e o tipo de treinamento (HAYKIN, 2001).

Conforme descrito na literatura (HAYKIN, 2001), se poucos neurônios forem usados na camada oculta, a rede neural não poderá modelar dados mais complexos, resultando em um ajuste inadequado. Se muitos neurônios forem usados, o treinamento em rede se tornará excessivamente longo e a rede poderá sofrer problemas de adaptação, resultando em perda de capacidade preditiva da rede, tornando-se importante o ajuste dos parâmetros.

A função não linear mais comumente usada na camada oculta de uma rede neural é a sigmóide, uma vez que é biologicamente mais plausível (HAYKIN, 2001). Semelhante à função sigmóide, a função tangente hiperbólica, $\tanh(x)$, também apresenta uma forma semelhante a S , mas varia de -1 a 1 ao invés de de 0 a 1 como no sigmóide (HAYKIN, 2001). A função $\tanh(x)$ preserva a forma sigmoideal da função logística, mas assume valores positivos e negativos, sendo assim uma alternativa mais atraente para servir como uma ativação para as camadas ocultas de RNAs (GOODFELLOW et al., 2016).

O aprendizado é o processo de adaptação dos parâmetros livres, pesos e limites,

⁵Equações não-lineares podem ter um numero infinito de soluções (AGUIRRE, 2007).

⁶Processo em que os parâmetros livres de uma rede neural são adaptados através de um mecanismo de apresentação de estímulos fornecidos pelo ambiente no qual a RNA está inserida (HAYKIN, 2001).

⁷A topologia de uma RNA representa a disposição dos neurônios na rede, como estão estruturados (HAYKIN, 2001).

de uma RNA através da interação com o ambiente no qual a rede está inserida. O algoritmo de aprendizado usado para o treinamento de redes neurais foi o algoritmo de Levenberg Marquadt, que resolve iterativamente problemas de minimização de funções não lineares pelo método dos mínimos quadrados (ISERMANN et al., 1997). O padrão de retropropagação usa a descida do gradiente como um método de aproximação da função de erro, que é o resultado da diferença entre o valor previsto e o valor real. O algoritmo de Levenberg Marquadt usa uma aproximação do método de Newton. Esta aproximação é obtida a partir da modificação do método de Gauss-Newton (ISERMANN et al., 1997), introduzindo um novo parâmetro maior ou igual a zero na diagonal da matriz jacobiana⁸. Este parâmetro funciona como um fator de estabilização do treinamento, ajustando a abordagem para usar a convergência rápida do método de Newton e evitando etapas muito grandes que podem levar a um erro de convergência (HAGAN; MENHAJ, 1994).

Na estrutura da RNA, as saídas dos neurônios em uma camada são entradas para a próxima camada. O resultado é então modificado por uma função não linear, neste caso a função tangente hiperbólica, antes da saída (HAYKIN, 2001).

A RNA *feed-forward*, composta por uma função não linear das entradas, representada como um conjunto de neurônios interconectados. O fluxo de dados opera apenas em um sentido (da esquerda para a direita), das entradas às saídas. Uma rede neural NAR, aplicada à previsão de séries temporais, descreve um modelo autorregressivo discreto, não linear, que pode ser escrito como (RUIZ et al., 2016)

$$Y(t) = r(u(k) + b). \quad (2)$$

A RNA-NAR pode ser usada para prever o valor de uma série $Y(t)$. A função $r(\cdot)$ é não linear e o treinamento da rede neural visa aproximar a função por meio de combinações lineares dos pesos da rede \mathbf{w} . O termo b denota o *bias*, i.e. o *offset* de aproximação das séries.

O outro modelo de redes neurais aplicado é a rede neural artificial com entradas exógenas (NARX). Os modelos NARX são frequentemente utilizados para busca melhores resultados do que as Redes neurais recorrentes convencionais. Os atrasos na saída da rede neural com entradas exógenas podem ajudar as dependências de longo prazo e podem ser encontradas considerando como os gradientes são calculados usando o algoritmo *back propagation*. (LIN et al., 1997) (YAO; TAN, 2000).

⁸É a matriz formada pelas derivadas parciais de primeira ordem de uma função vetorial.

Observou-se em estudos de séries temporais que a previsão pode ser aprimorada pela análise simultânea com entradas exógenas. No modelo de previsão de consumo de energia elétrica, chega-se a um melhor resultado usando os seguintes dados de entrada em conjunto: consumos de energia do último dia (entrada) e média de temperatura ambiente (entrada exógena) aplicados simultaneamente como entradas para a rede neural (DIACONESCU, 2008).

2.3.2 Modelo Autorregressivo Linear

O Modelo Autorregressivo Linear tem características flexíveis, permitindo ajustes e adaptações em seus parâmetros, contribuindo para que diferentes tipos de séries temporais sejam representados, assumindo assim, que a variável de saída depende linearmente de seus valores passados e de um processo estocástico⁹.

Existem duas maneiras de se olhar para modelos de regressão (CAMELO et al., 2017):

- Processar todas as informações das variáveis dependentes e independentes e determinar um vetor final de parâmetros de estimação, também conhecida como estimação em batelada.
- Processar sucessivamente as observações das variáveis, dependentes e independentes, ajustando as estimativas à medida que os dados vão sendo conhecidos, também conhecida como estimação recursiva.

Para o modelo proposto neste trabalho foi utilizado o estimador recursivo pelo método dos mínimos quadrados, que pode ser utilizado em regressão estática ou para estimar os parâmetros de um modelo dinâmico, em que a soma dos quadrados dos resíduos é minimizada (AGUIRRE, 2007). Neste caso, a velocidade média do vento, tentando minimizar a soma dos quadrados das diferenças entre o valor estimado e os dados observados, cuja diferença entre os valores é o erro de previsão.

Para chegar ao estimador recursivo de mínimos quadrados, inicia-se pela definição da atualização recursiva, forma escalar de uma equação a diferenças, representada por

$$y(k) = \phi^T(k-1)\hat{\Theta}_k + \varepsilon(k), \quad (3)$$

⁹Se refere a uma grandeza que evolui ao longo do tempo pela ação de um mecanismo aleatório (AGUIRRE, 2007).

em que $y(k)$ é a saída do estimador recursivo, $\phi^T(k-1)$ é o vetor de regressores transposto, $\hat{\Theta}_k$ é o vetor de parâmetros estimado na iteração k e $\varepsilon(k)$ representa o resíduo entre o valor previsto e valor medido.

Costuma-se expressar $\hat{\Theta}_k$ em função do valor estimado no momento anterior $\hat{\Theta}_{k-1}$. A nova estimativa de parâmetros, precisa incorporar a última medida $y(k)$, no instante k , desta forma, conforme (AGUIRRE, 2007) propõe a

$$\hat{\Theta}_k = J_k \hat{\Theta}_{k-1} + K_k y(k). \quad (4)$$

em que, J_k e K_k devem ser determinados da forma que $\hat{\Theta}_k$ seja um bom estimador. O vetor de parâmetros é expresso pela combinação linear do seu valor no instante anterior e do valor da medição no instante k . Um estimador razoável, conforme (YOUNG, 2012) deve ser não polarizado e a covariância de $\hat{\Theta}_k$ deve ser a menor possível.

A polarização é definida por

$$b = E[\hat{\Theta}] - \Theta, \quad (5)$$

em que $E[.]$ é a esperança matemática, observando que neste caso $\hat{\Theta}$ é um vetor de variáveis aleatórias e θ é um valor determinístico ainda desconhecido. Como a diferença entre $\hat{\Theta} - \theta$ é composta por variáveis aleatórias, deve-se usar a esperança matemática (AGUIRRE, 2007). O estimador recursivo, como dito anteriormente, não deve ser polarizado, ou seja, $E[\hat{\Theta}_k] - \theta = 0$.

A parcela de inovação $\eta(k)$ do estimador recursivo é composta pelo erro de predição realizado pelo modelo na previsão do valor em um instante k , utilizando um vetor de parâmetros conhecidos no instante anterior ($k-1$), conforme (AGUIRRE, 2007)

$$\eta(k) = y(k) - \phi(k)^T \hat{\Theta}_{k-1}. \quad (6)$$

O vetor de parâmetros $\phi(k-1)$ é um dado conhecidos do sistema, representados matematicamente na equação (19),

$$\phi(k-1) = [y(k-1) \ y(k-2) \ \dots \ y(k-n)]. \quad (7)$$

em que n é a quantidade de regressores utilizada.

O processo para o estimador recursivo de mínimos quadrados, como visto, começa

de (3) e a sequência de dados com a velocidade do vento, representados por $y(k)$ e $\phi(k-1)$. O estimador recursivo de mínimos quadrados $\hat{\Theta}_k$ pode ser escrito da seguinte forma

$$\hat{\Theta}_{MQk} = \left[\sum_{i=1}^k \phi(i-1)\phi^T(i-1) \right]^{-1} \left[\sum_{i=1}^k \phi(i-1)y(i) \right], \quad (8)$$

cuja dedução é apresentada em AGUIRRE (2007).

Como estimativa da matriz P_k de $\hat{\Theta}_k$ pode ser usada a notação (AGUIRRE, 2007)

$$P_k = \left[\sum_{i=1}^k \phi(i-1)\phi^T(i-1) \right]^{-1}. \quad (9)$$

Nas equações (8) e (9) representa as grandezas da matriz de covariância e $\hat{\Theta}_k$ em um determinado instante k em função de valores em instantes passados. Omitindo a indicação MQ e seguindo um procedimento análogo $\hat{\Theta}_k$ pode ser reescrito conforme (AGUIRRE, 2007)

$$\hat{\Theta}_k = P_k \left[\sum_{i=1}^k \phi(i-1)y(i) + \phi(k-1)y(k) \right]. \quad (10)$$

Escrevendo a equação (8) para o instante $k-1$ e representando de forma compacta o primeiro termo da equação como $P_{k-1}^{-1}\hat{\Theta}_{k-1}$, pode-se chegar ao seguinte resultado quando aplicado na equação 10 (AGUIRRE, 2007), sendo K_k uma matriz de ganho.

$$\hat{\Theta}_k = \hat{\Theta}_{k-1} + K_k\eta(k). \quad (11)$$

O cálculo de P_k através da equação (9) é inadequado, pois requer inversão de matriz a cada iteração. A expressão numericamente vantajosa pode ser obtida aplicando o lema da inversão de matrizes, resultando na equação 12 (AGUIRRE, 2007).

$$P_k = P_{k-1} - P_{k-1}\phi(k-1)(\phi^T(k-1)P_{k-1}\phi(k-1) + 1)^{-1}\phi^T(k-1)P_{k-1} \quad (12)$$

Aplicando a equação (12) na matriz de ganho $K_k = P_k\phi(k-1)$ chega-se na equação (15). Colocando em ordem apropriada as equações 11 e 12, lembrando que $\phi(k) = \phi(k-1)$, ou seja, o vetor de regressores atualizado na interação k contém

informação até o instante anterior $k - 1$, obtém-se as equações (13) e (14) (AGUIRRE, 2007).

$$P_k = P_{k-1} - K_k \phi_k^T P_{k-1}, \quad (13)$$

$$\hat{\Theta}_k = \hat{\Theta}_{k-1} + K + k \left[y(k) - \phi_k^T \hat{\Theta}_{k-1} \right], \quad (14)$$

$$K_k = P_{k-1} \phi_k \left[\phi_k^T P_{k-1} \phi_k - 1 \right]^{-1}. \quad (15)$$

A estimação recursiva de parâmetros variantes no tempo pode ponderar de maneira diferenciada as observações disponíveis. A aplicação do fator de esquecimento permite que entradas antigas do modelo tenham um peso menor do que o dado mais recente, através do processo em que no momento um novo dado é recebido, todos os pesos são multiplicados por um fator de esquecimento λ . Este fator varia entre 0,9 e 0,99, ou seja, menor que um, reduzindo os valores da matriz P_k , permitindo um maior ganho de correção (AGUIRRE, 2007).

O estimador recursivo de mínimos quadrados para a previsão da velocidade do vento tem um resultado superior quando são esquecidos regressores antigos, pois o fenômeno de variação da velocidade do vento tem maior relação com dados recentes do que dados mais antigos. Desta forma, é aplicado o fator de esquecimento λ em (13) e (15) permitindo que os regressores mais recentes possuam uma maior importância no modelo proposto. Reescrevendo as equações do estimador recursivo de mínimos quadrados com o fator de esquecimento, tem-se

$$P_k = \frac{1}{\lambda} (P_{k-1} - K_k \phi_k^T P_{k-1}), \quad (16)$$

$$\hat{\Theta}_k = \hat{\Theta}_{k-1} + K + k \left[y(k) - \phi_k^T \hat{\Theta}_{k-1} \right], \quad (17)$$

$$K_k = P_{k-1} \phi_k \left[\phi_k^T P_{k-1} \phi_k - 1 \right]^{-1}. \quad (18)$$

De forma análoga ao proposto no modelo das RNAs, entradas exógenas pode ser utilizadas para os modelos autorregressivos. Reescrevendo o vetor de dados conhecidos $\phi(k - 1)$ de entrada, tem-se a entrada exógena $x(k - 1)$ como um dos itens que compõe o vetor

$$\phi(k - 1) = [y(k - 1) \ y(k - 2) \ y(k - 3) \ y(k - 3) \ x(k - 1)]. \quad (19)$$

Adicionalmente à entrada exógena, o modelo autorregressivo linear pode ter a

média móvel, $\xi(k)$, inclusa no vetor de entrada, $\phi(k-1)$. De forma prática, o valor real $y(k)$ é comparado ao valor previsto $\phi_k^T \hat{\Theta}_k$ no modelo de previsão. O termo médias móveis parte do conceito de que a saída do modelo de previsão é constituído a partir da soma ponderada dos valores mais recentes de $\xi(k)$ (AGUIRRE, 2007), demonstrada em (20) cujo resultado segue como entrada do vetor $\phi(k-1)$, representado em (21).

$$\xi(k) = y(k) - \phi_k^T \hat{\Theta}_k. \quad (20)$$

$$\phi(k-1) = [y(k-1) \ y(k-2) \ y(k-3) \ x_i(k-1) \ x(k-1)]. \quad (21)$$

2.4 MODELO DE AVALIAÇÃO DO DESEMPENHO DOS MODELOS DE PREVISÃO

Buscando um comparativo com demais trabalhos desenvolvidos na área de previsão anemométrica, medidas de desempenho foram utilizadas em termos da Raiz do Erro Médio Quadrático e Coeficiente de Correlação Linear (R^2) conforme Zameer (ZAMEER et al., 2017).

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (V_m - V_p)^2}, \quad (22)$$

$$R^2 = \frac{\sum_{n=1}^N (V_m - \bar{V}_m)(V_p - \bar{V}_p)}{\sqrt{\sum_{n=1}^N (V_m - \bar{V}_m)^2 \sum_{n=1}^N (V_p - \bar{V}_p)^2}}, \quad (23)$$

em que V_m e V_p representam os valores de velocidade do vento medido e previsto, respectivamente.

O R^2 é expresso em valor normalizado, cujo resultado quando mais próximo a 1 indica uma maior correlação linear. A RMSE representa as diferenças individuais quadráticas entre as séries temporais reais e previstas. A unidade de medida dos resultados em RMSE é a velocidade do vento em m/s.

2.5 ANÁLISE DE CORRELAÇÃO CRUZADA PARA ENTRADAS EXÓGENAS

Considerando duas séries temporais $X_{1,t=0}^{\infty}$ e $X_{2,t=0}^{\infty}$ estacionárias¹⁰ com médias $\mu_1 = E(X_{1,t})$ e $\mu_2 = E(X_{2,t})$, variâncias de $\sigma_1^2 = Var(X_{1,t})$ e $\sigma_2^2 = Var(X_{2,t})$ para $t = 1, 2, \dots, n$, como entradas para a função de covariância cruzada ($\gamma_{1,2}(h)$) e correlação cruzada $\rho_{1,2}(h)$ que são definidas nas equações (24) e (25) respectivamente.

$$\gamma_{1,2}(h) = E \left[(X_{1,t} - \mu_1)(X_{2,t+h} - \mu_2) \right], \quad (24)$$

$$\rho_{1,2}(h) = \frac{E \left[(X_{1,t} - \mu_1)(X_{2,t+h} - \mu_2) \right]}{\sigma_1^2 \sigma_2^2}, \quad (25)$$

em que h pertence ao conjunto de números inteiros.

A análise de correlação cruzada¹¹ das entradas exógenas dos modelos de previsão desenvolvidos neste trabalho deve identificar as variáveis que possuem maior correlação com a velocidade do vento. Uma entrada exógena com melhor correlação cruzada com a velocidade do vento tem potencial de reduzir o erro dos modelos de previsão da velocidade do vento.

Também identifica-se através da correlação cruzada se duas potenciais entradas exógenas são fortemente correlacionadas, cenário no qual pode-se abdicar de uma das duas, visto que a correlação encontrada pode acabar não agregando valor como entrada dos modelos de previsão (HIRUMA, 2016).

¹⁰Processo é estacionário quando as leis da probabilidade que o regem não se alteram ao longo do tempo, está em equilíbrio estatístico (AGUIRRE, 2007).

¹¹Função que quantifica o grau de semelhança entre dois sinais em função do defasamento entre eles (AGUIRRE, 2007).

3 METODOLOGIA

Em agosto de 2019 foram instaladas cinco torres anemométricas com altura de 30 metros na RMC. Estas estações realizam medições anemométricas que devem compor o modelo de microescala ¹, que em conjunto com os dados do modelo de mesoescala ², serão o ponto referencial para o atlas de energia eólica da RMC.

O atlas eólico dos municípios da RMC, apoiado pela Companhia Paranaense de Energia (COPEL), visa disponibilizar o mapa eólico dessas regiões com resolução de 50 metros. Esses mapas serão fontes relevantes de dados para direcionar e incentivar a micro e mini geração eólica na região. A microgeração distribuída refere-se à geração, com potência instalada menor ou igual a 100 quilowatts (kW). A minigeração distribuída diz respeito à geração com potência instalada superior a 100 kW e menor ou igual a 1 megawatt (MW) (ANEEL, 2014).

O modelo de previsão de dados anemométricos proposto neste trabalho será validado com os dados adquiridos destas estações e poderá ser aplicado para correções em falhas das medições que podem interferir na qualidade do modelo de microescala do atlas desenvolvido.

Os modelos de previsão da velocidade do vento propostos estão separados em três classes:

- *One Steap Ahead* (OSA): Os modelos OSA utilizam como entrada do modelo de previsão os valores medidos no instante anterior da velocidade do vento de instantes anteriores ao longo de todo o processo de previsão.
- *k Steap Ahead* (KSA): Os modelos KSA utilizam como entrada do modelo de previsão os valores medidos da velocidade do vento de instantes anteriores ao longo de todo o processo de previsão.
- *Free Run Simulation* (FRS): Os modelos FRS utilizam os dados medidos da velocidade do vento somente para inicializar o modelo, nas próximas iterações as entradas são as saídas dos instantes anteriores do modelo de previsão.

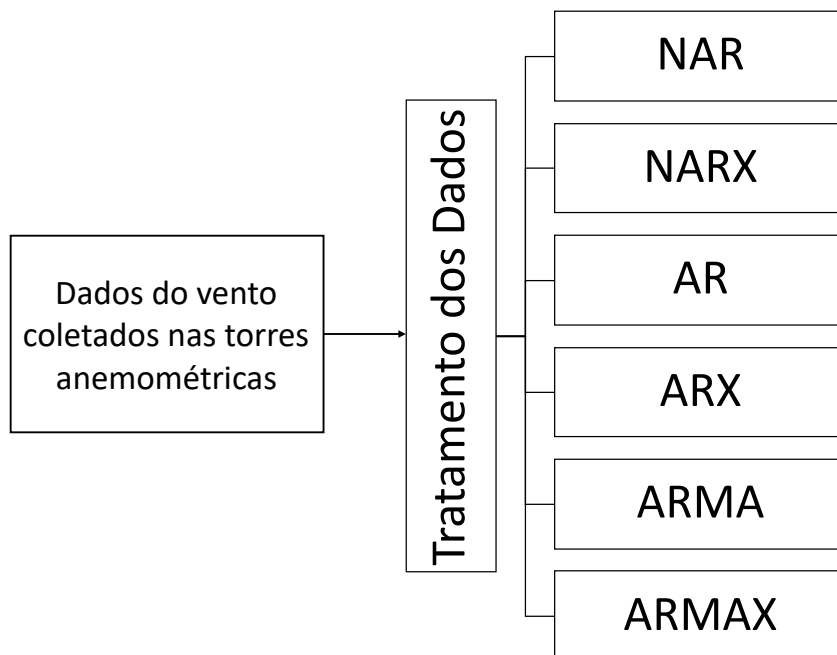
¹Os modelos de microescala tem as características do vento em um determinado local, com informações do relevo. Apresentam uma maior resolução. Escala do modelo menor que 1 km (YEMER, 2010)

²Modelos em mesoescala são utilizados para análise de vento em grandes áreas. Fornecem uma visão geral da velocidade do vento, têm resolução baixa e não incluem os efeitos topográficos locais. Usualmente com escala superior a 1km (YEMER, 2010).

Os modelos descritos acima utilizam os dados do vento em ambiente urbano das cinco torres instaladas na RMC. A previsão da série temporal é feita através dos modelos:

- NAR: Modelo Autorregressivo Não Linear.
- NARX: Modelo Autorregressivo Não Linear com entrada exógena.
- AR: Modelo Autorregressivo Linear.
- ARMA: Modelo Autorregressivo Linear de Média Móvel.
- ARX: Modelo Autorregressivo Linear com entrada exógena.
- ARMAX: Modelo Autorregressivo Linear de Média Móvel com entrada exógena.

Figura 5 – Modelos Propostos.



Fonte: Autoria própria.

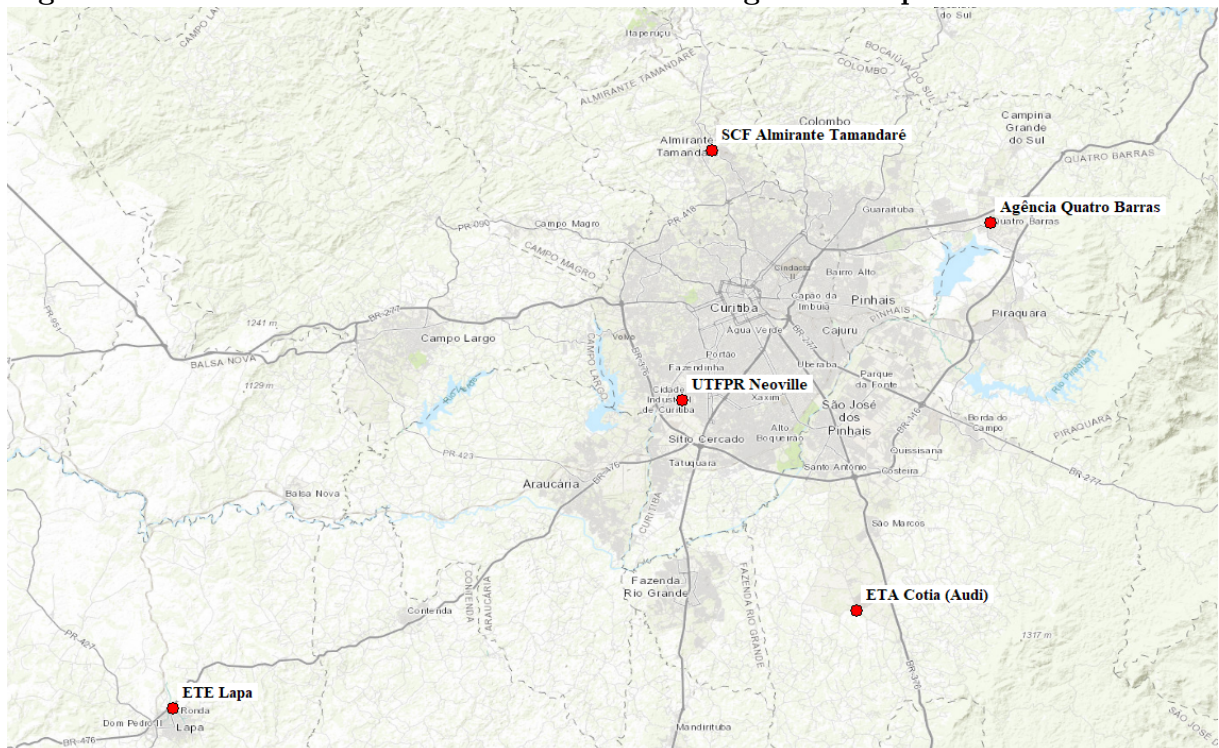
Os resultados encontrados são comparados com o intuito de determinar o melhor modelo de previsão da velocidade do vento para cada localidade.

3.1 COLETA DE DADOS E PRÉ PROCESSAMENTO

As torres anemométricas instaladas na RMC estão representadas pelos pontos vermelhos no mapa da Figura 6. Todas as torres possuem anemômetro primeira classe,

do inglês *first class*, estes modelos possuem as características mínimas exigidas pela EPE para medição da intensidade do vento, instalados na altura de 20 e 30 m, cada qual com um sensor de direção do vento ou anemoscópio, do inglês *windvane*, instalados na mesma altura de 20 e 30m, sendo demonstrado na Figura 7 uma das torres instaladas. Os dados de cada torre são registrados no *Datalogger* da marca YDOC, a partir do qual tem-se comunicação remota para extração remota dos dados por rede celular.

Figura 6 – Torres Anemométricas instaladas na região metropolitana de Curitiba.



Fonte: Autoria própria.

O pré-processamento realizado nos dados tem como objetivo eliminar inconsistências encontradas nas medidas, sejam elas por problemas no instrumento de medição, fonte de alimentação (bateria) ou comunicação. Neste caso para análise e tratamento dos dados, é utilizado o *software* Windographer, programa de análise de dados de vento que lê arquivos de dados a partir de torres anemométricas, facilitando a análise, através da interface gráfica, de possíveis inconsistências nas medições descritas anteriormente, permitindo também a exclusão de dados inconsistentes.

Após este processamento dos dados, as medições são exportadas em formato *txt*, utilizado posteriormente pelo *software* que irá desenvolver o modelo de previsão das medições anemométricas, contendo a média dos valores instantâneos a cada dez minutos com a velocidade do vento, direção do vento, temperatura e umidade.

Figura 7 – Torre instalada no campus Neville da UTFPR.



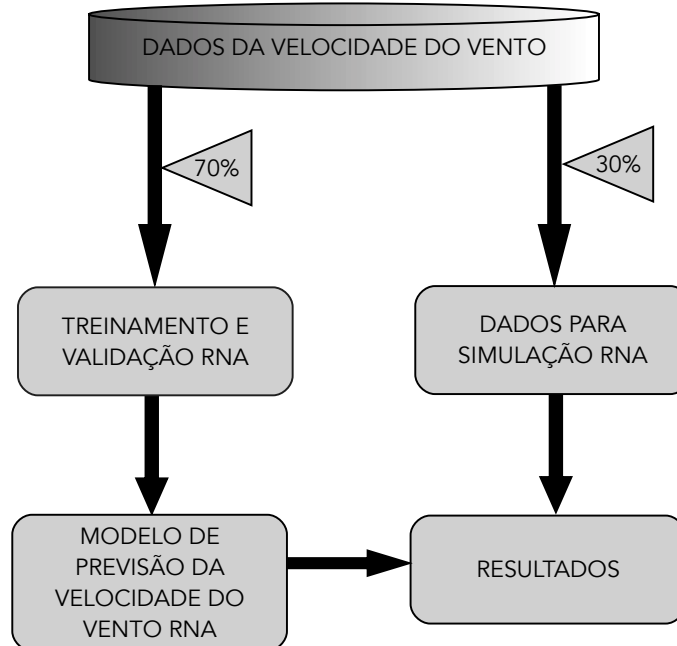
Fonte: Autoria própria.

Estes dados coletados são unidos em pacotes e são utilizados como os dados de entrada dos modelos de previsão RNA e autorregressivo linear.

3.2 MODELO RNA

O modelo proposto na Figura 8 recebe os dados da velocidade do vento das torres anemométricas instaladas, realizadas as leituras da velocidade do vento a cada 10 minutos durante um ano. A rede neural é treinada utilizando 70% dos dados. Após o treinamento da rede neural, obtém-se o modelo de previsão de velocidade do vento por redes neurais artificiais. Os 30% restantes dos dados de velocidade do vento são utilizados para a simulação do modelo desenvolvido, avaliando os resultados obtidos para a simulação da velocidade do vento, e para esta simulação as últimas três, cinco ou sete medições da velocidade do vento são utilizadas para obter a previsão da próxima medida, conforme o modelo estudado. Após a simulação, o valor previsto é comparado com o valor real da medição.

Figura 8 – Modelo de Previsão por Redes Neurais Artificiais.



Fonte: Autoria própria.


Conforme mencionado anteriormente, os dados de velocidade do vento observados neste trabalho representam medições realizadas em um intervalo de dez minutos entre o período de agosto de 2019 e agosto de 2020 em cinco torres anemométricas instaladas na RMC. O anemômetro de referência para a medição da velocidade do vento foi instalado a 30 metros do solo.

Para a análise dos resultados são utilizadas 1.000 amostras de dados de velocidade do vento coletadas a cada dez minutos por período. Além disso, as características do modelo de rede neural proposto, mostrado na Figura 8, possuem dez neurônios em uma única camada oculta, que apresenta empiricamente o melhor desempenho para essa RNA. As alternativas foram testadas através das tentativas de diversas topologias, buscando a solução com o menor RMSE e maior R^2 , no qual foram avaliadas diversas variáveis para a quantidade de camadas ocultas, quantidade de neurônios e o número de dados de entrada.

Como mostrado na Figura 9, o modelo de rede neural proposto consiste em dez neurônios na camada oculta, tangente hiperbólica como a função de ativação, Levenberg Marquadt como o algoritmo de treinamento. Este modelo considera cinco atrasos nos dados de entrada, ou seja, são utilizadas as últimas cinco medições anemométricas (50 minutos atrás, sendo uma medida a cada dez minutos) para prever o próximo instante de medição.

Os sinais de entrada da velocidade do vento nos cinco instantes anteriores, dados por $u(k) = [Y(t-1) Y(t-2) Y(t-3) Y(t-4) Y(t-5)]$, em que os dados da velocidade do vento em instantes anteriores $Y(t-n)$ entram na camada oculta da RNA, que é composta por neurônios e cada um encontra-se associado ao seu respectivo peso. Através dessa combinação é possível obter uma saída linear que é a soma ponderada dos pesos associados aos dados de entrada. Uma função de ativação é aplicada em cada camada oculta de neurônios e na saída, geralmente envolvendo comparações matemáticas (MORI; UMEZAWA, 2009).

Figura 9 – Modelo NAR-RNA com entradas t na camada oculta composta por neurônios $+$, sendo que os pesos (W) e *bias* (b) são aplicados na função tangente hiperbólica, com um dado de saída passando pela camada de saída composta de uma função linear pura.



Fonte: Autoria própria.


Na Figura 10 tem-se o modelo RNA-NARX proposto neste trabalho, semelhante ao modelo RNA-NAR apresentado anteriormente, cuja diferença está concentrada em utilizar entradas exógenas ($xi(t)$) nos sinais de entrada, dados por $u(k) = [Y(t-1) Y(t-2) Y(t-3) Y(t-4) xi(t-1)]$.

3.3 MODELO DE PREVISÃO AUTORREGRESSIVO LINEAR

O modelo proposto na Figura 11 recebe os dados da velocidade do vento das torres anemométricas instaladas. Seguindo a mesma lógica referente à divisão dos dados da velocidade de vento explicado anteriormente para o modelo RNA, o modelo de previsão autorregressivo linear recebe as leituras da velocidade do vento integralizadas a cada 10 minutos.

O bloco com a nomenclatura AR da Figura 11, se refere ao algoritmo de mínimos quadrados descrito matematicamente em (16), (17) e (18). As cinco últimas medidas previstas, $u(k)$, pelo Modelo Autorregressivo Linear são as entradas. Como inicialmente

Figura 10 – Modelo NARX-RNA com entradas n na camada oculta composta por neurônios p , sendo que os pesos (w) e *bias* (b) são aplicados na função tangente hiperbólica, com um dado de saída passando pela camada de saída composta de uma função linear pura.




Fonte: Autoria própria.

não existem as cinco medidas previstas pelo modelo, define-se como condição inicial os cinco últimos valores realmente medidos pela estação anemométrica. A saída Y_p , deste modelo é a previsão da velocidade do vento para os próximos 10 minutos. O fator de esquecimento λ para este modelo de previsão foi encontrado de forma empírica, em que os valores de 0,95 e 0,90 apresentaram bom desempenho com as demais características do modelo de previsão expostas acima. Neste trabalho o fator de esquecimento igual a 0,90 obteve melhor desempenho devido ao fato que os dados passados não são tão relevantes como os mais recentes para a previsão da velocidade do vento.

Destaca-se que também foram feitas variações do modelo representado na Figura 11, no qual inclui-se entradas exógenas em $u(k)$, levando ao modelo ser chamado de autorregressivo com entradas exógenas (ARX). A segunda variação do modelo autorregressivo linear feita no presente trabalho inclui na entrada $u(k)$ o valor MA, para este modelo a nomenclatura adotada é ARMA. Por fim, a terceira variação do modelo autorregressivo linear é o modelo ARMAX, no qual é realizado a junção do modelo autorregressivo linear com entradas exógenas e média móvel.

Figura 11 – Modelo de Previsão Autorregressivo Linear.



Fonte: Autoria própria.

Para a análise dos resultados são utilizadas 1.000 amostras de dados de velocidade do vento coletadas a cada dez minutos. Além disso, as características do modelo autorregressivo linear, mostrado na Figura 11, utiliza como entrada as cinco amostras passadas da velocidade do vento, entrada exógena (temperatura, direção do vento ou umidade) e média móvel (comparação entre o valor real com o valor previsto), dependendo do modelo em questão.

3.4 SELEÇÃO DO MODELO DE PREVISÃO

Para disponibilizar os dados de entrada e comparação entre real e previsto, deve ser utilizada uma interface de comunicação que possa fornecer informações ao modelo RNA e modelo autorregressivo *one step ahead* em tempo real, como um sistema SCADA ou uma comunicação celular.

Na prática pode-se afirmar que apesar de mais eficiente, os modelos de previsão *one step ahead* recebem as entradas da velocidade do vento em instantes anteriores para seu funcionamento, o que pode gerar prejuízo nos valores previstos quando ocorrer algum problema na estação anemométrica, que não permita disponibilizar estes dados ao modelo. Entre os possíveis problemas que podem ocorrer tem-se a queima do anemômetro, problema na bateria, problema nos cabos ou em suas conexões (DAMASCENO et al., 2008). Desta forma, uma combinação dos modelos *one step ahead* e *free run simulation* se torna efetiva, pois quando ocorrer um problema na disponibilização da velocidade do vento em instantes anteriores, o modelo FRS, que utiliza os valores previstos nos instantes anteriores como entrada, pode entrar em ação e continuar a previsão até a correção do problema dos dados medidos na torre anemométrica.

4 RESULTADOS

Na Tabela 1 e da Figura 12 até a 16 são demonstrados os resultados dos dados coletados e processados nas cinco torres anemométricas da Região Metropolitana de Curitiba, onde verifica-se as características do vento nos cinco pontos de referência para os modelos de previsão.

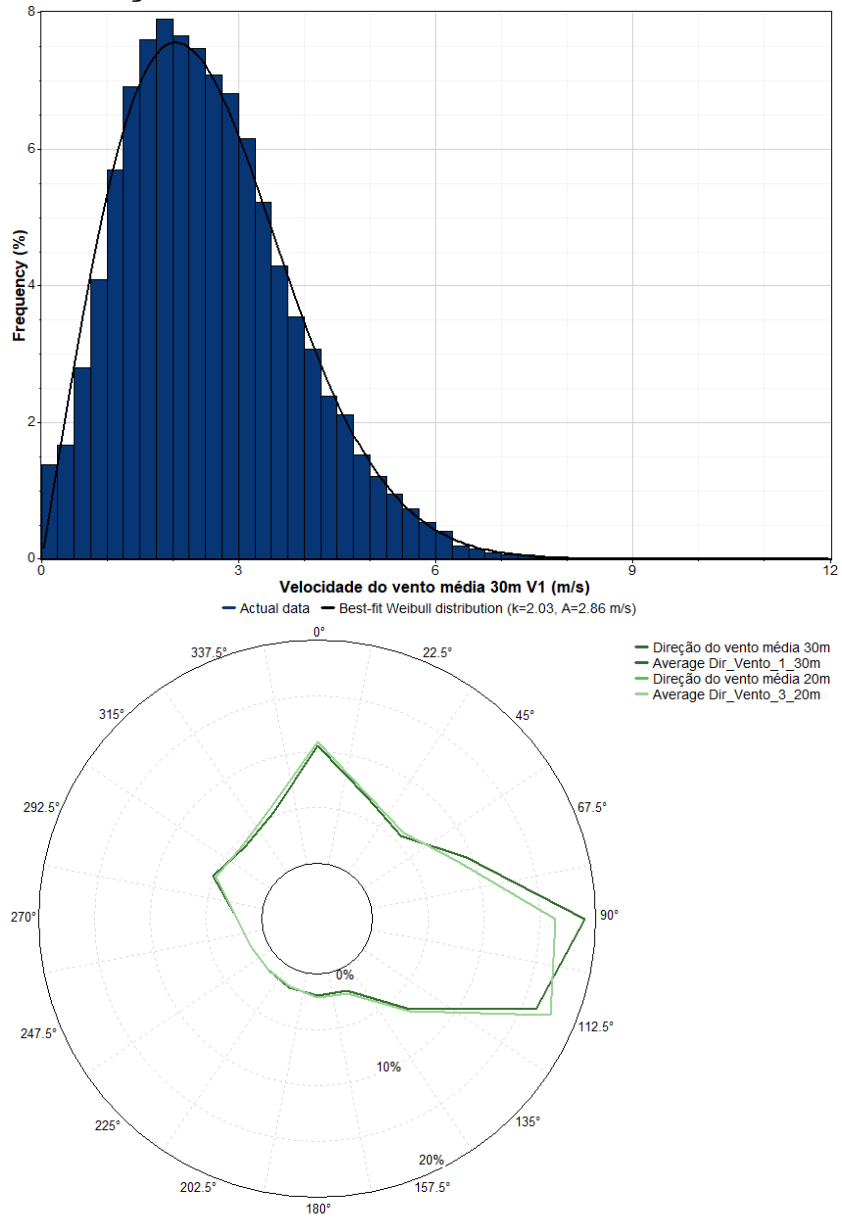
Tabela 1 – Resumo dos dados medidos nas torres anemométricas instaladas na RMC.

	Velocidade Média do Vento (<i>m/s</i>)	Temperatura Média (<i>°C</i>)
Torre 1	2,55	18,59
Torre 2	3,73	18,12
Torre 3	3,12	18,93
Torre 4	3,60	19,04
Torre 5	3,36	18,11

Fonte: Autoria própria.

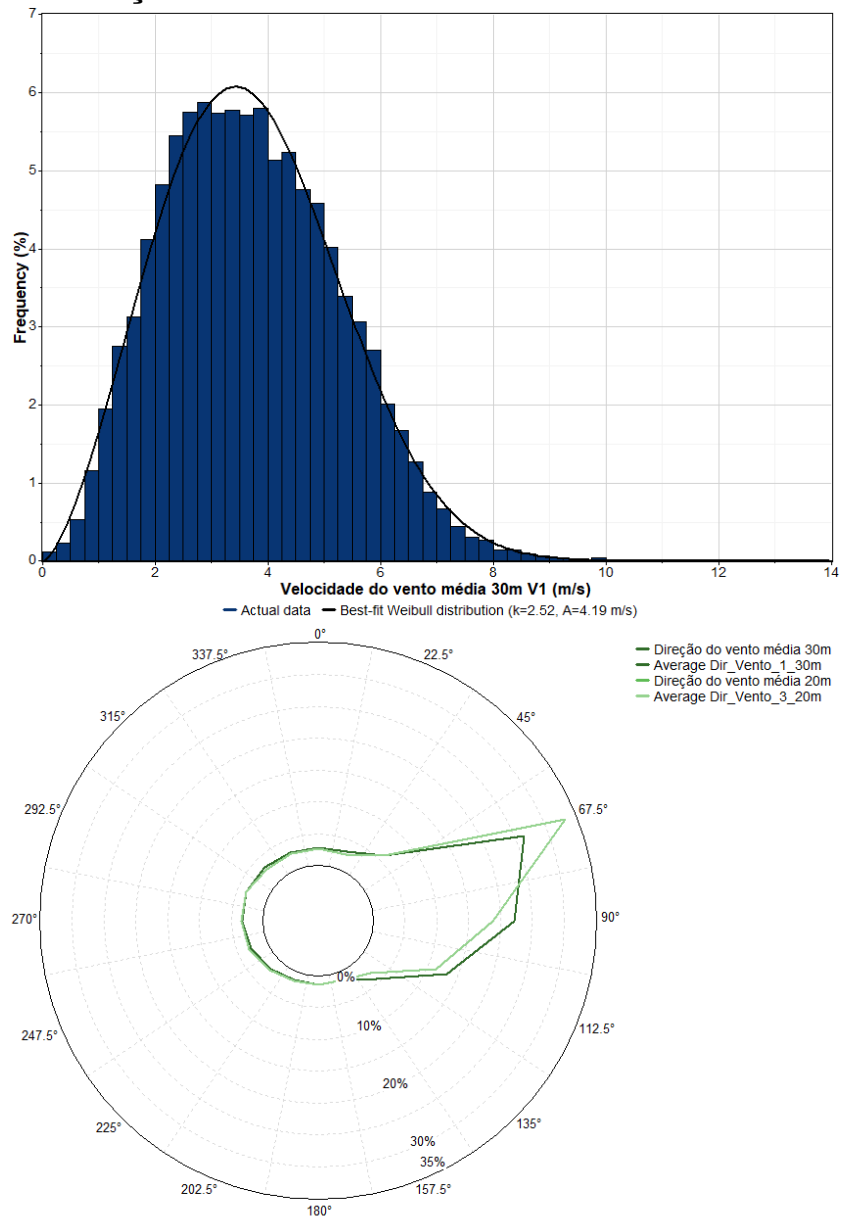
A característica da velocidade do vento é importante para conhecer o recurso eólico de um local, em que a frequência de ocorrência de cada velocidade do vento pode ser avaliada através da distribuição de Weibull (SOUZA et al., 2019).

Figura 12 – Distribuição de Weibull e Rosa dos Ventos da Torre 1



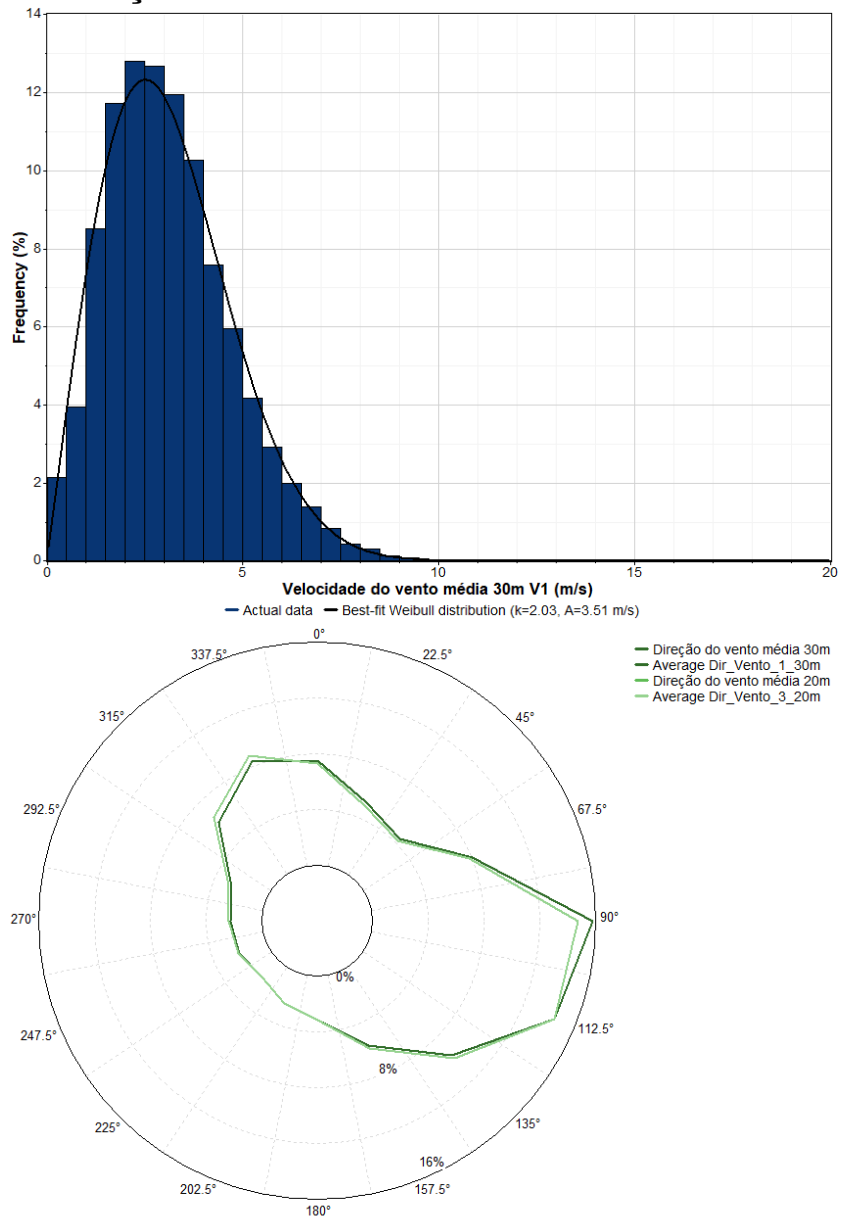
Fonte: Autoria própria.

Figura 13 – Distribuição de Weibull e Rosa dos Ventos da Torre 2



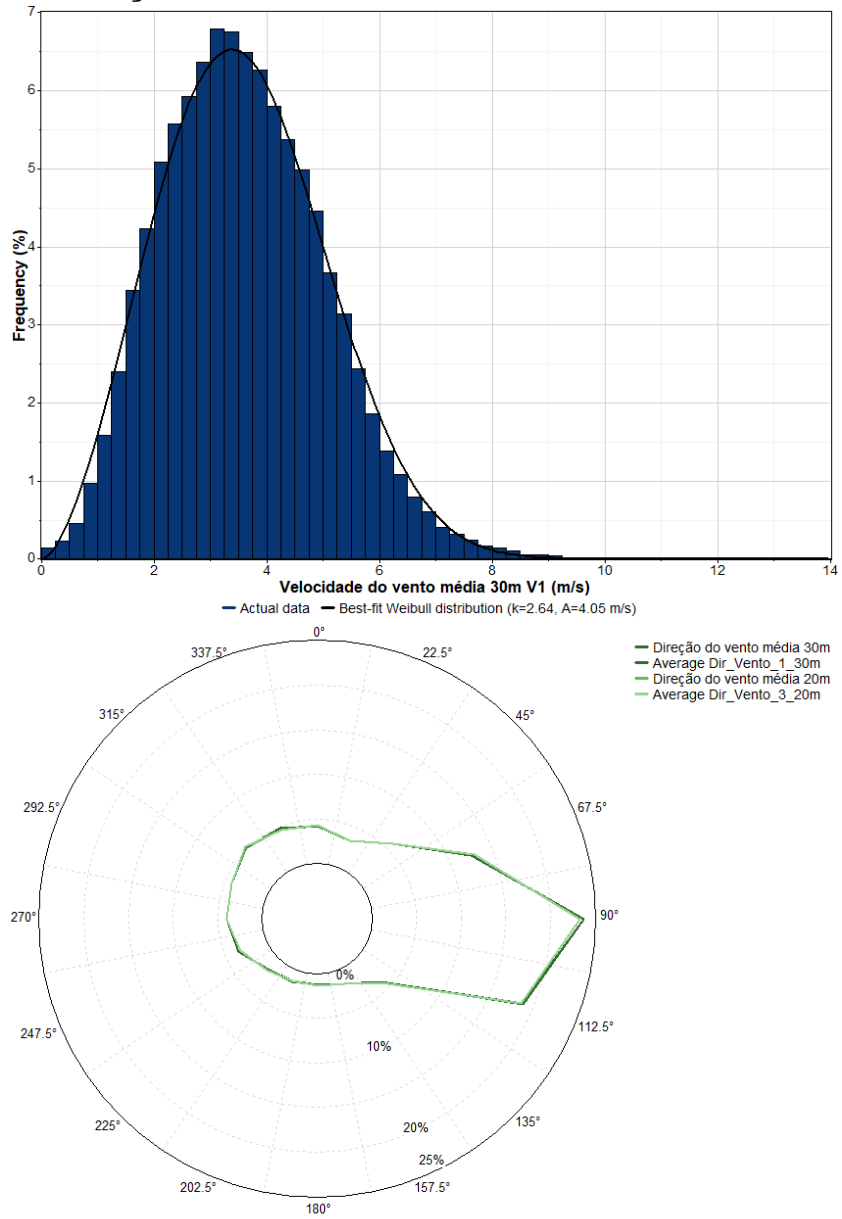
Fonte: Autoria própria.

Figura 14 – Distribuição de Weibull e Rosa dos Ventos da Torre 3



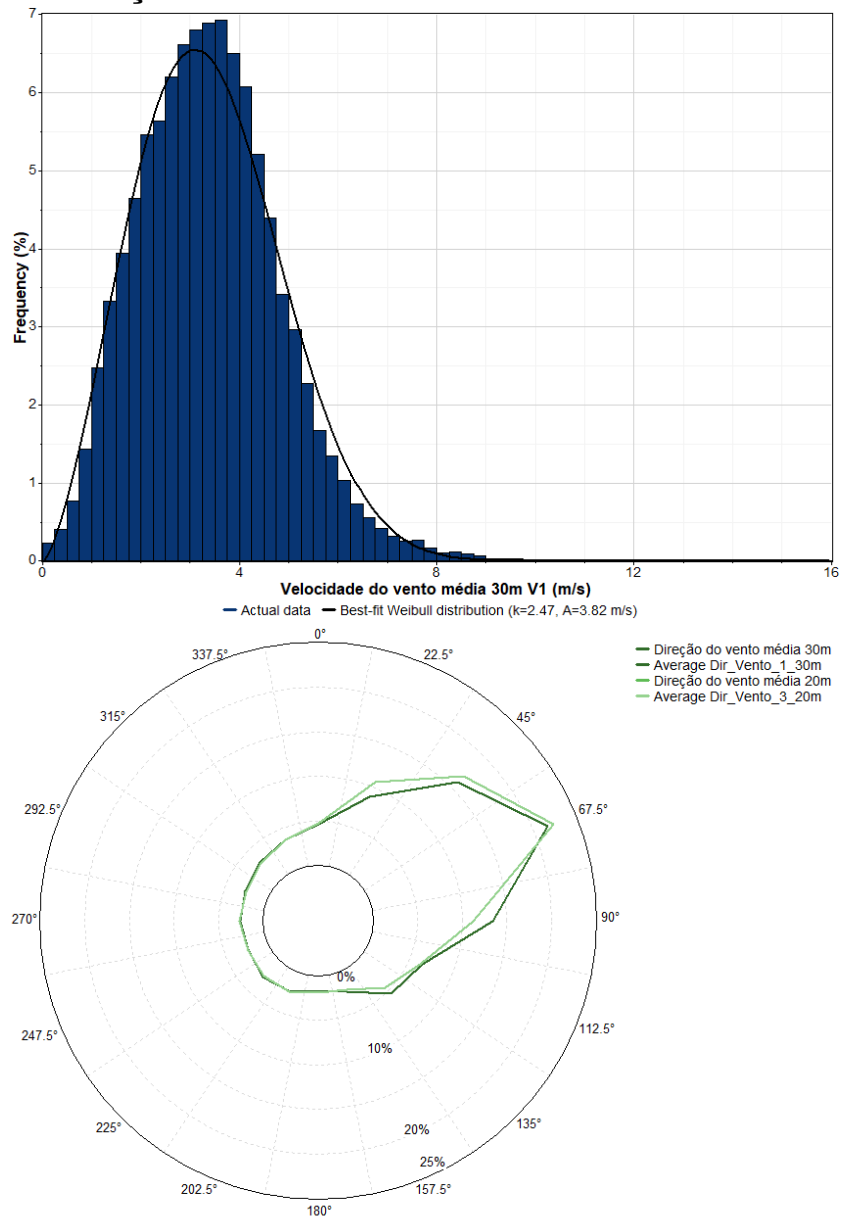
Fonte: Autoria própria.

Figura 15 – Distribuição de Weibull e Rosa dos Ventos da Torre 4



Fonte: Autoria própria.


Figura 16 – Distribuição de Weibull da Torre 5



Fonte: Autoria própria.


Nas figuras 17 e 18 são apresentadas a correlação cruzada da velocidade do vento com as entradas exógenas e a correlação cruzada entre as entradas exógenas coletadas em uma das cinco torres anemométricas da RMC.

Figura 17 – Torre 1: Correlação cruzada da velocidade do vento com as entradas exógenas.



Fonte: Autoria própria.

Figura 18 – Torre 1: Correlação cruzada entre as entradas exógenas.



Fonte: Autoria própria.

A entrada exógena que apresenta a maior correlação cruzada com a velocidade do vento é a temperatura, conforme pode-se analisar na Tabela 2.

Os resultados da correlação cruzada média da Tabela 3 sugerem que as entradas exógenas de umidade e direção do vento apresentam a maior correlação cruzada média entre elas, ou seja, conclui-se que a inclusão de uma ou outra variável não se complementa tão bem quanto a inclusão da temperatura com a direção do vento, que possui uma menor

Tabela 2 – Correlação cruzada média entre velocidade do vento e entradas exógenas

Correlação cruzada média	Torre 1	Torre 2	Torre 3	Torre 4	Torre 5
Direção do Vento	0,302	0,002	0,211	0,043	0,129
Temperatura	0,572	0,263	0,445	0,309	0,406
Umidade	-0,474	0,038	-0,347	-0,210	-0,145

Fonte: Autoria própria.

correlação (0,233).

Tabela 3 – Correlação cruzada média entre entradas exógenas


Correlação Cruzada média	Torre 1	Torre 2	Torre 3	Torre 4	Torre 5
Direção do Vento x Temperatura	0,294	0,200	0,065	0,199	0,405
Temperatura x Umidade	-0,514	-0,489	-0,440	-0,364	-0,583
Umidade x Direção do Vento	-0,491	-0,588	-0,379	-0,371	-0,615

Fonte: Autoria própria.

4.1 MODELO RNA


Nas Figuras 19 até 23, a velocidade do vento prevista pelo modelo NAR que possui três entradas é comparada à velocidade do vento medida em um intervalo de previsão de uma semana para as torres 1 a 5. A partir das Figuras, pode-se verificar visualmente a correspondência entre os valores medidos e os previstos. O RMSE obtido é de 0,525 m/s, 0,553 m/s, 0,530 m/s, 0,481 m/s e 0,529 m/s, já o R^2 é de 0,766, 0,847, 0,897, 0,845 e 0,832 respectivamente.

Figura 19 – Torre 1: Rede Neural Artificial com 5 dados de entrada e 10 neurônios na camada oculta (NAR 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 20 – Torre 2: Rede Neural Artificial com 5 dados de entrada e 10 neurônios na camada oculta (NAR 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 21 – Torre 3: Rede Neural Artificial com 5 dados de entrada e 10 neurônios na camada oculta (NAR 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 22 – Torre 4: Rede Neural Artificial com 5 dados de entrada e 10 neurônios na camada oculta (NAR 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.



Fonte: Autoria própria.

Figura 23 – Torre 5: Rede Neural Artificial com 5 dados de entrada e 10 neurônios na camada oculta (NAR 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.



Fonte: Autoria própria.

Além do modelo de previsão da RNA com cinco dados de entrada e dez neurônios na camada oculta, os modelos com três e sete dados de entradas foram desenvolvidos, assim como o modelo com cinco dados de entradas e vinte neurônios na camada oculta. Os resultados encontrados para estes modelos são apresentados nas Tabelas 4 e 5.


O R^2 identificado nos modelos de previsão por RNA varia sensivelmente na terceira casa decimal com as variações realizadas na quantidade de entradas ou neurônios na camada oculta, sendo que o valor médio do R^2 das torres 1 a 5 é igual para os casos de 5 e 7 entradas do modelo de previsão, assim como a variação de 10 ou 20 neurônios na camada oculta. O modelo de previsão por RNA com 3 entradas apresentou resultados 0,12% inferiores aos demais.

Desenvolveu-se o modelo de RNA com entradas exógenas, no qual as variáveis de temperatura, direção do vento ou umidade foram incluídas aos dados de entrada em conjunto com a velocidade do vento em instantes anteriores.

O modelo RNA com entradas exógenas que obteve o melhor desempenho foi o que utilizou como entrada exógena a temperatura, pois para a massa de dados utilizada neste trabalho é a que possui a maior correlação cruzada com a velocidade do vento. As Figuras 24 a 28 representam o resultado encontrado comparado ao valor medido nas torres anemométricas. O RMSE obtido para este modelo RNA com entrada exógena de temperatura das torres 1 a 5 é de 0,515 m/s, 0,544 m/s, 0,522 m/s, 0,475 m/s e 0,520


m/s, já o R^2 encontrado é de 0,778, 0,853, 0,890, 0,84 e 0,838 respectivamente.

Figura 24 – Torre 1: Rede Neural Artificial com 5 dados de entrada, 10 neurônios na camada oculta e temperatura como entrada exógena (NARX3 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 25 – Torre 2: Rede Neural Artificial com 5 dados de entrada, 10 neurônios na camada oculta e temperatura como entrada exógena (NARX3 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 26 – Torre 3: Rede Neural Artificial com 5 dados de entrada, 10 neurônios na camada oculta e temperatura como entrada exógena (NARX3 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 27 – Torre 4: Rede Neural Artificial com 5 dados de entrada, 10 neurônios na camada oculta e temperatura como entrada exógena (NARX3 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.



Fonte: Autoria própria.

Figura 28 – Torre 5: Rede Neural Artificial com 5 dados de entrada, 10 neurônios na camada oculta e temperatura como entrada exógena (NARX3 5d10n). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Como pode-se observar nos resultados apresentados nesta seção, a inclusão da entrada exógena melhora o resultado do modelo de previsão por RNA. O R^2 do modelo RNA com entrada exógena temperatura obteve uma melhoria de 0,35% quando comparado ao modelo RNA sem a entrada exógena. Enquanto que o modelo RNA com entradas exógenas de temperatura, direção do vento e umidade obteve uma melhoria de R^2 0,47% acima do modelo RNA sem entrada exógena.

4.2 MODELO DE PREVISÃO AUTORREGRESSIVO LINEAR


A velocidade do vento prevista pelo modelo Autorregressivo linear é comparada à velocidade do vento medida em um intervalo de previsão de uma semana. A partir das Figuras 29 a 33, pode-se verificar visualmente uma correspondência entre os valores medidos e os previstos, superior ao encontrado no melhor modelo da RNA sem entrada exógena. Com o fator de esquecimento igual a 1, o RMSE obtido para os modelos de previsão AR das torres 1 a 5 são respectivamente 0,520 m/s, 0,547 m/s, 0,515 m/s, 0,473 m/s e 0,521 m/s, com o R^2 de 0,776, 0,854, 0,903, 0,853 e 0,841.

Figura 29 – Torre 1: Modelo autorregressivo linear com 5 dados de entrada e fator de esquecimento um (AR 5dl1). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 30 – Torre 2: Modelo autorregressivo linear com 5 dados de entrada e fator de esquecimento um (AR 5dl1). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 31 – Torre 3: Modelo autorregressivo linear com 5 dados de entrada e fator de esquecimento um (AR 5dl1). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 32 – Torre 4: Modelo autorregressivo linear com 5 dados de entrada e fator de esquecimento um (AR 5dl1). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.



Fonte: Autoria própria.


Figura 33 – Torre 5: Modelo autorregressivo linear com 5 dados de entrada e fator de esquecimento um (AR 5dl1). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.



Fonte: Autoria própria.


Assim como desenvolvido para a RNA, foram incluídas entradas exógenas no modelo autorregressivo linear, no qual um dos melhores resultados encontrados do modelo ARX OSA possui como entradas exógenas a temperatura, direção do vento e umidade medidas no instante anterior (dez minutos antes) da previsão da velocidade do vento desejada. Com o fator de esquecimento igual a 0,9, o RMSE obtido para os modelos de previsão ARX das torres 1 a 5 são 0,336 m/s, 0,361 m/s, 0,342 m/s, 0,306 m/s e 0,348 m/s, já o R^2 é de 0,904, 0,936, 0,957, 0,937 e 0,927 respectivamente. Estes resultados estão demonstrados nas Figuras 34 a 38. Como pode-se observar são resultados superiores aos encontrados na melhor rede neural artificial OSA com entradas exógenas.

Figura 34 – Torre 1: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 35 – Torre 2: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 36 – Torre 3: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 37 – Torre 4: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.



Fonte: Autoria própria.


Figura 38 – Torre 5: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.



Fonte: Autoria própria.


Devido ao resultado do modelo autorregressivo linear com entradas exógenas, que apresentou baixo RMSE quando comparado aos demais modelos, decidiu-se avaliar o resultado do modelo de previsão da velocidade do vento prevendo um horizonte maior da velocidade do vento de dez minutos para trinta minutos a frente, utilizando um modelo KSA. Mantendo todas as características do modelo ARX1 5dl0,9 apresentado, o RMSE encontrado para as torres 1 a 5 são respectivamente 0,674 m/s, 0,789 m/s, 0,797 m/s, 0,684 m/s e 0,787 m/s, com o R^2 de 0,637, 0,710, 0,778, 0,706 e 0,655. Nas Figuras 39 a 43 pode-se observar um resultado inferior ao modelo que prevê a velocidade do vento com horizonte de dez minutos. Desta forma limitou-se os modelos de previsão desenvolvidos neste trabalho para o horizonte de previsão até 30 minutos a frente da velocidade do vento.

Figura 39 – Torre 1: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9 30min). Dados de velocidade do vento de uma semana (1000) previstos a cada trinta minutos.




Fonte: Autoria própria.

Figura 40 – Torre 2: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9 30min). Dados de velocidade do vento de uma semana (1000) previstos a cada trinta minutos.




Fonte: Autoria própria.

Figura 41 – Torre 3: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9 30min). Dados de velocidade do vento de uma semana (1000) previstos a cada trinta minutos.




Fonte: Autoria própria.

Figura 42 – Torre 4: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9 30min). Dados de velocidade do vento de uma semana (1000) previstos a cada trinta minutos.



Fonte: Autoria própria.

Figura 43 – Torre 5: Modelo autorregressivo linear com 5 dados de entrada, fator de esquecimento 0,9 e entradas exógenas de temperatura, umidade e direção do vento (ARX1 5dl0,9 30min). Dados de velocidade do vento de uma semana (1000) previstos a cada trinta minutos.




Fonte: Autoria própria.

Finalmente, outro modelo autorregressivo foi feito, utilizando as cinco últimas medidas previstas pelo Modelo Autorregressivo Linear como entradas, sendo que inicialmente, como não existem as cinco medidas previstas pelo modelo, define-se como condição inicial os cinco últimos valores realmente medidos pela estação anemométrica, este método tem a nomenclatura apresentada de FRS, apresentada no início deste capítulo.


O modelo autorregressivo linear FRS que apresenta o melhor resultado é o Modelo Autorregressivo Linear de média móvel com 5 dados de entrada e fator de esquecimento 0,9, utilizando como entrada exógena a temperatura, demonstrado nas Figuras 44 a 48. O RMSE encontrado para as torres 1 a 5 são de 0,348 m/s, 0,367 m/s, 0,341 m/s, 0,310 m/s e 0,348 m/s, e R^2 de 0,897, 0,933, 0,957, 0,936 e 0,927 respectivamente.

Figura 44 – Torre 1: Modelo autorregressivo linear FRS com 5 dados de entrada, fator de esquecimento 0,9, média móvel e entrada exógena de temperatura (ARMAX2 5dl0,9). Dados de velocidade do vento de uma semana (1.000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 45 – Torre 2: Modelo autorregressivo linear FRS com 5 dados de entrada, fator de esquecimento 0,9, média móvel e entrada exógena de temperatura (ARMAX2 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 46 – Torre 3: Modelo autorregressivo linear FRS com 5 dados de entrada, fator de esquecimento 0,9, média móvel e entrada exógena de temperatura (ARMAX2 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.




Fonte: Autoria própria.

Figura 47 – Torre 4: Modelo autorregressivo linear FRS com 5 dados de entrada, fator de esquecimento 0,9, média móvel e entrada exógena de temperatura (ARMAX2 5dl0,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.



Fonte: Autoria própria.

Figura 48 – Torre 5: Modelo autorregressivo linear FRS com 5 dados de entrada, fator de esquecimento 0,9, média móvel e entrada exógena de temperatura (ARMAX2 5d10,9). Dados de velocidade do vento de uma semana (1000) previstos a cada dez minutos.



Fonte: Autoria própria.

4.3 ANÁLISE DOS RESULTADOS

Os resultados encontrados apontam um melhor desempenho do modelo autorregressivo linear comparado a RNA, quando o modelo de previsão utiliza as medidas efetivas reais dos instantes anteriores como entrada, este método é conhecido como *one step ahead*. Devido ao Modelo Autorregressivo apresentar um resultado superior, foi feito também para este modelo pelo método *free run simulation*, em que as próprias previsões do modelo são as entradas para as previsões futuras.

Nos modelos de previsão por RNA, o modelo com entrada exógena de temperatura (NARX3 5d10n) disposto nas Tabelas 4 e 5 obteve os melhores resultados, com RMSE médio de 0,515 m/s e R^2 de 0,841, possuindo uma redução do RMSE de 1,38% e aumento do R^2 de 0,44% quando comparado ao modelo sem entrada exógena. Mesmo sendo o melhor modelo encontrado para RNA, quando comparado com os modelos autorregressivos com entrada exógena (ARX) identifica-se uma redução no RMSE de 33,15% e aumento do R^2 de 10,67%.

Entre os modelos autorregressivos FRS, o modelo ARMAX2 com entrada exógena temperatura e fator de esquecimento igual a 0,9 obteve os melhores resultados, com o RMSE médio de 0,343 m/s e R^2 de 0,93. Também comprovou-se que o desempenho deste

modelo tem o RMSE 17,59% menor e o R^2 3,58% maior que o mesmo modelo com fator de esquecimento igual a 0,95.

Tabela 4 – Resultados RMSE

Processo	Modelo de Previsão	Torre 1	Torre 2	Torre 3	Torre 4	Torre 5
OSA	NAR 5d10n	0,525	0,553	0,530	0,481	0,529
OSA	NAR 7d10n	0,524	0,552	0,525	0,481	0,527
OSA	NAR 3d10n	0,526	0,554	0,532	0,482	0,528
OSA	NAR 5d20n	0,525	0,553	0,526	0,480	0,528
OSA	NARX1 5d10n	0,525	0,546	0,524	0,467	0,521
OSA	NARX2 5d10n	0,527	0,555	0,527	0,478	0,527
OSA	NARX3 5d10n	0,515	0,544	0,522	0,475	0,520
OSA	AR 5dl1	0,520	0,547	0,515	0,473	0,521
OSA	AR 5dl0,95	0,431	0,454	0,421	0,388	0,428
OSA	AR 5dl0,9	0,360	0,381	0,351	0,324	0,358
OSA	ARX1 5dl0,9	0,336	0,361	0,342	0,306	0,348
OSA	ARX1 5dl0,95	0,411	0,439	0,420	0,374	0,420
OSA	ARX2 5dl0,9	0,343	0,372	0,347	0,307	0,355
OSA	ARX2 5dl0,95	0,423	0,448	0,419	0,373	0,427
OSA	ARX3 5dl0,9	0,339	0,364	0,338	0,306	0,343
OSA	ARX3 5dl0,95	0,414	0,441	0,412	0,374	0,417
KSA	AR 5dl0,9 30min	0,704	0,814	0,797	0,705	0,799
KSA	AR 5dl0,95 30min	0,715	0,837	0,821	0,719	0,825
KSA	ARX1 5dl0,9 30min	0,674	0,789	0,797	0,684	0,787
FRS	AR 5dl0,9	0,476	0,538	0,494	0,421	0,482
FRS	AR 5dl0,95	0,631	0,754	0,769	0,560	0,738
FRS	ARMA 5dl0,9	0,363	0,387	0,352	0,324	0,372
FRS	ARMA 5dl0,95	0,433	0,455	0,421	0,389	0,439
FRS	ARMAX1 5dl0,9	0,359	0,375	0,350	0,319	0,362
FRS	ARMAX2 5dl0,9	0,348	0,367	0,341	0,310	0,348
FRS	ARMAX2 5dl0,95	0,418	0,444	0,413	0,376	0,423

Fonte: Autoria própria.

Ademais, os modelos de previsão propostos atuam em poucos milisegundos, prevendo a velocidade do vento dos próximos dez minutos com as cinco medições anteriores, obtendo resultados eficientes em comparação com a literatura. Em NOOROLLAHI et al. (2016), o RMSE para a cidade de Abadeh, no Irã, usando uma rede neural de retropropagação, do inglês *backpropagation*, era de 1,17 m/s. Em LIU et al. (2018b), o RMSE obtido para o modelo ARIMA é de 0,99 m/s. Os autores em LIU et al. (2018b) também desenvolveram uma Rede Neural Elman, que produziu RMSE de 0,62 m/s.

É importante ressaltar que comparar modelos de previsão usando diferentes

Tabela 5 – Resultados R^2

Processo	Modelo de Previsão	Torre 1	Torre 2	Torre 3	Torre 4	Torre 5
OSA	NAR 5d10n	0,766	0,847	0,897	0,845	0,832
OSA	NAR 7d10n	0,767	0,847	0,899	0,845	0,833
OSA	NAR 3d10n	0,767	0,848	0,897	0,843	0,833
OSA	NAR 5d20n	0,768	0,847	0,898	0,846	0,832
OSA	NARX1 5d10n	0,768	0,853	0,899	0,854	0,838
OSA	NARX2 5d10n	0,765	0,848	0,898	0,847	0,835
OSA	NARX3 5d10n	0,778	0,853	0,890	0,849	0,838
OSA	AR 5dl1	0,776	0,854	0,903	0,853	0,841
OSA	AR 5dl0,95	0,845	0,899	0,936	0,901	0,893
OSA	AR 5dl0,9	0,891	0,929	0,955	0,931	0,924
OSA	ARX1 5dl0,9	0,904	0,936	0,957	0,937	0,927
OSA	ARX1 5dl0,95	0,857	0,905	0,936	0,907	0,894
OSA	ARX2 5dl0,9	0,900	0,931	0,956	0,937	0,924
OSA	ARX2 5dl0,95	0,848	0,900	0,935	0,907	0,890
OSA	ARX3 5dl0,9	0,902	0,934	0,958	0,937	0,929
OSA	ARX3 5dl0,95	0,854	0,903	0,938	0,907	0,895
KSA	AR 5dl0,9 30min	0,617	0,695	0,781	0,693	0,653
KSA	AR 5dl0,95 30min	0,604	0,679	0,768	0,681	0,633
KSA	ARX1 5dl0,9 30min	0,637	0,710	0,778	0,706	0,655
FRS	AR 5dl0,9	0,817	0,863	0,914	0,885	0,869
FRS	AR 5dl0,95	0,703	0,749	0,821	0,801	0,722
FRS	ARMA 5dl0,9	0,889	0,927	0,955	0,930	0,918
FRS	ARMA 5dl0,95	0,844	0,899	0,936	0,900	0,887
FRS	ARMAX1 5dl0,9	0,891	0,930	0,955	0,932	0,922
FRS	ARMAX2 5dl0,9	0,897	0,933	0,957	0,936	0,927
FRS	ARMAX2 5dl0,95	0,851	0,902	0,937	0,905	0,892

Fonte: Autoria própria.

bancos de dados de medidas de velocidade do vento não é a melhor alternativa, pois cada localidade tem suas características específicas, podendo impactar diretamente nos resultados dos diversos modelos de previsão do vento encontrados na literatura, mas atualmente não existem padrões difundidos para comparação.

5 CONCLUSÃO

Neste trabalho foi proposto um modelo de previsão de dados anemométricos por Redes Neurais Artificiais e Modelos Autorregressivos para a região metropolitana de Curitiba. Os resultados obtidos para os modelos de previsão, apresentaram um RMSE médio de aproximadamente 0,3 m/s na amplitude velocidade do vento, para previsão no horizonte de dez minutos.

Mesmo com as particularidades não lineares das variáveis meteorológicas no interior da camada limite atmosférica, não justificaram o melhor desempenho dos modelos das Redes Neurais Artificiais em relação ao modelo autorregressivo. Devido ao resultado superior do Modelo Autorregressivo Linear, também foram realizados para este modelo ensaios em *free run simulation*, levando a resultados semelhantes aos modelos autorregressivos *one step ahead*. Observa-se na literatura e nos resultados encontrados que a inclusão de outras variáveis atmosféricas melhoram o desempenho do modelo de previsão da RNA e dos modelos autorregressivos.

A previsão de dados anemométricos proposta neste trabalho resolve o problema pontual para os dados anemométricos na RMC, nos locais onde as estações anemométricas estão instaladas, entretanto este modelo não é eficaz para a previsão de dados anemométricos de outra localidade. Para cada situação em específico é necessário desenvolvimento de um modelo de previsão, embora o método construtivo desenvolvido neste trabalho possa auxiliar na elaboração de um modelo de previsão do vento em outras regiões.

Esta área de estudo ainda possui bastante campo a ser explorado, existe a tendência de crescimento da geração eólica em ambientes urbanos e conseqüentemente a necessidade da previsão dos dados anemométricos para uma operação cada vez mais assertiva e segura.

Como trabalho futuro, o modelo de previsão autorregressivo linear pode ter a integralização agregada à média móvel com entrada exógena. Para o modelo RNA outras topologias como a Elman e convolucional podem ser avaliadas. Adicionalmente, a previsão de geração de energia eólica de uma turbina eólica em operação pode ser feita a partir do modelo de previsão da velocidade do vento desenvolvido neste trabalho.

REFERÊNCIAS

- ABEOLICA. **Boletim Anual de Geração 2017**. 2018. Disponível em: <http://abeeolica.org.br/wp-content/uploads/2018/04/Boletim-Anual-de-Geracao-2017.pdf>. Acesso em: 13 set. 2018.
- AGUIRRE, L. A. Introdução a identificação de sistemas: técnicas lineares e não-lineares aplicadas a sistemas reais. **Editora da UFMG. 3ª edição**, 2007.
- AMARANTE, O. A.; BROWER, M.; ZACK, J.; EOLICA, C. S. E.; SOLUTIONS, T. Atlas do potencial eólico brasileiro. In: **Atlas do potencial eólico brasileiro**. Ministério de Minas e Energia/Eletrobras, 2001.
- ANEEL. **Agência Nacional de Energia Elétrica**. 2014. Disponível em: <https://www2.aneel.gov.br/biblioteca/downloads/livros/caderno-tematico-microeminigeracao.pdf>. Acesso em: 13 mar. 2020.
- CAMELO, H. d. N. Modelos híbridos estocástico-matemático para previsão de velocidade do vento. Brasil, 2018.
- CAMELO, H. d. N.; LUCIO, P. S.; JUNIOR, J. B. V. L.; CARVALHO, P. C. M. de. Métodos de previsão de séries temporais e modelagem híbrida ambos aplicados em médias mensais de velocidade do vento para regiões do nordeste do Brasil. **Revista Brasileira de Meteorologia**, SciELO Brasil, v. 32, n. 4, p. 565–574, 2017.
- CAMELO, H. do N. Utilização de regressão dinâmica harmônica através do software livre r para previsão de séries temporais de velocidade do vento em regiões do nordeste brasileiro. **REVISTA DE ENGENHARIA E TECNOLOGIA**, v. 9, n. 2, p. páginas–55, 2017.
- CAMELO, H. do N.; TEIXEIRA, W. F.; LUCIO, P. S.; JUNIOR, J. B. V. L. Previsão de velocidade média do vento através da utilização de modelagem auto-regressiva de médias móveis (arma) em região serrana no estado do Ceará-Brasil. **Revista Brasileira de Energias Renováveis**, v. 4, n. 3, 2015.
- CHANG, G.; LU, H.; CHANG, Y.; LEE, Y. An improved neural network-based approach for short-term wind speed and power forecast. **Renewable energy**, Elsevier, v. 105, p. 301–311, 2017.
- DAMASCENO, J. C.; ANTONIO, J.; OLIVEIRA, S. P. de. **Avaliação de dados de medição—Guia para a expressão de incerteza de medição**. sn, 2008.
- DIACONESCU, E. The use of narx neural networks to predict chaotic time series. **Wseas Transactions on computer research**, Citeseer, v. 3, n. 3, p. 182–191, 2008.
- DOUCOURE, B.; AGBOSSOU, K.; CARDENAS, A. Time series prediction using artificial wavelet neural network and multi-resolution analysis: Application to wind speed data. **Renewable Energy**, Elsevier, v. 92, p. 202–211, 2016.

DUTRA, R. M.; SZKLO, A. S. Hydro-wind power complementarity: a way to implementing wind power in brazil. In: **Proceedings World Renewable Energy Congress**. 2008. p. 19–25.

EPE. **EPE - Empresa de Pesquisa Energética**. 2017. Disponível em: <http://www.epe.gov.br>. Acesso em: 02 jan. 2020.

GONÇALVES, A. R.; PEREIRA, E. B.; MARTINS, F. R. Previsão de curto prazo da geração eólico-elétrica para o nordeste brasileiro por redes neurais artificiais. In: **III Congresso de Energia Solar. Belém-PA**. 2010.

GONZÁLEZ-APARICIO, I.; MONFORTI, F.; VOLKER, P.; ZUCKER, A.; CARERI, F.; HULD, T.; BADGER, J. Simulating european wind power generation applying statistical downscaling to reanalysis data. **Applied Energy**, Elsevier, v. 199, p. 155–168, 2017.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. MIT press, 2016.

GWEC. **Global Wind Report 2017**. 2017. Disponível em: <http://gwec.net/publications/global-wind-report-2/>. Acesso em: 19 out. 2018.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the Marquardt algorithm. **IEEE transactions on Neural Networks**, IEEE, v. 5, n. 6, p. 989–993, 1994.

HAYKIN, S. **Redes neurais princípios prática. Vol. 2**. Editora Bookman, Porto Alegre, 2001.

HIRUMA, F. S. Previsão da geração de energia eólica com redes neurais artificiais. 2016.

ISERMANN, R.; ERNST, S.; NELLES, O. Identification with dynamic neural networks-architectures, comparisons, applications. **IFAC Proceedings Volumes**, Elsevier, v. 30, n. 11, p. 947–972, 1997.

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

KAUR, T.; KUMAR, S.; SEGAL, R. Application of artificial neural network for short term wind speed forecasting. In: IEEE. **2016 Biennial international conference on power and energy systems: towards sustainable energy (PESTSE)**. 2016. p. 1–5.

LIN, T.-N.; GILES, C. L.; HORNE, B. G.; KUNG, S.-Y. A delay damage model selection algorithm for narx neural networks. **IEEE Transactions on Signal Processing**, IEEE, v. 45, n. 11, p. 2719–2730, 1997.

LIU, H.; DUAN, Z.; HAN, F.-z.; LI, Y.-f. Big multi-step wind speed forecasting model based on secondary decomposition, ensemble method and error correction algorithm. **Energy Conversion and Management**, Elsevier, v. 156, p. 525–541, 2018.

LIU, H.; MI, X.; LI, Y. Smart deep learning based wind speed prediction model using wavelet packet decomposition, convolutional neural network and convolutional long short term memory network. **Energy Conversion and Management**, Elsevier, v. 166, p. 120–131, 2018.

- LYDIA, M.; KUMAR, S. S.; SELVAKUMAR, A. I.; KUMAR, G. E. P. Linear and non-linear autoregressive models for short-term wind speed forecasting. **Energy Conversion and Management**, Elsevier, v. 112, p. 115–124, 2016.
- MORI, H.; UMEZAWA, Y. Application of nbtrees to selection of meteorological variables in wind speed prediction. In: IEEE. **Transmission & Distribution Conference & Exposition: Asia and Pacific, 2009**. 2009. p. 1–4.
- NOAA. **Numerical Weather Prediction**. 2020. Disponível em: <https://www.ncdc.noaa.gov/data-access/model-data/model-datasets/numerical-weather-prediction>. Acesso em: 04 fev. 2020.
- NOOROLLAHI, Y.; JOKAR, M. A.; KALHOR, A. Using artificial neural networks for temporal and spatial wind speed forecasting in iran. **Energy Conversion and Management**, Elsevier, v. 115, p. 17–25, 2016.
- PINTO, M. de O. **Fundamentos de energia eólica**. Grupo Gen-LTC, 2013.
- RUIZ, L.; CUÉLLAR, M.; CALVO-FLORES, M.; JIMÉNEZ, M. An application of non-linear autoregressive neural networks to predict energy consumption in public buildings. **Energies**, Multidisciplinary Digital Publishing Institute, v. 9, n. 9, p. 684, 2016.
- SOUZA, A. de; OLIVEIRA, S. S. de; OZONUR, D. Análise estatística de parâmetros de weibull para avaliação de potencial de energia eólica em campo grande. **Journal of Environmental Analysis and Progress**, v. 4, n. 3, p. 168–179, 2019.
- SOUZA, R. C. **Previsão da distribuição da densidade de probabilidade da Geração de Energia Eólica usando técnicas não paramétricas**. 2015. Tese (Doutorado) — PUC-Rio, 2015.
- TEALAB, A.; HEFNY, H.; BADR, A. Forecasting of nonlinear time series using ann. **Future Computing and Informatics Journal**, Elsevier, v. 2, n. 1, p. 39–47, 2017.
- VARSHNEY, K.; PODDAR, K. Prediction of wind properties in urban environments using artificial neural network. **Theoretical and Applied Climatology**, Springer Science and Business Media LLC, v. 107, n. 3-4, p. 579–590, Aug 2011. ISSN 1434-4483. Disponível em: <http://dx.doi.org/10.1007/s00704-011-0506-9>.
- WANG, H.-z.; LI, G.-q.; WANG, G.-b.; PENG, J.-c.; JIANG, H.; LIU, Y.-t. Deep learning based ensemble approach for probabilistic wind power forecasting. **Applied energy**, Elsevier, v. 188, p. 56–70, 2017.
- WANG, X.; GUO, P.; HUANG, X. A review of wind power forecasting models. **Energy procedia**, Elsevier, v. 12, p. 770–778, 2011.
- WENDEL, M.; FERREIRA, T. V. B.; DAVID, P. A. M.-S. Impacto da perda de dados anemométricos na estimativa do recurso eólico. **SNPTEE**, p. 8, 10 2017.
- WHEELWRIGHT, S.; MAKRIDAKIS, S.; HYNDMAN, R. J. **Forecasting: methods and applications**. John Wiley & Sons, 1998.
- YAO, J.; TAN, C. L. A case study on using neural networks to perform technical forecasting of forex. **Neurocomputing**, Elsevier, v. 34, n. 1-4, p. 79–98, 2000.

YEMER, F. M. **Urban Windmap for Delft, Rotterdam and Zoetermeer**. 2010. 115 p. Dissertação (Mestrado) — Delft University of Technology, 2010.

YOUNG, P. C. **Recursive estimation and time-series analysis: an introduction**. Springer Science & Business Media, 2012.

ZAMEER, A.; ARSHAD, J.; KHAN, A.; RAJA, M. A. Z. Intelligent and robust prediction of short term wind power using genetic programming based ensemble of neural networks. **Energy conversion and management**, Elsevier, v. 134, p. 361–372, 2017.

ZHANG, G. P. Time series forecasting using a hybrid arima and neural network model. **Neurocomputing**, Elsevier, v. 50, p. 159–175, 2003.

ZHAO, J.; GUO, Z.-H.; SU, Z.-Y.; ZHAO, Z.-Y.; XIAO, X.; LIU, F. An improved multi-step forecasting model based on wrf ensembles and creative fuzzy systems for wind speed. **Applied energy**, Elsevier, v. 162, p. 808–826, 2016.