

RICARDO SILVA PARENTE

**MODELO HÍBRIDO UTILIZANDO HOLT-WINTERS E REDE NEURAL NÃO
LINEAR AUTOREGRESSIVA COM ENTRADAS EXÓGENAS (NARX) PARA
PREVISÃO DA VELOCIDADE DO VENTO**

MANAUS – AM
2021

RICARDO SILVA PARENTE

**MODELO HÍBRIDO UTILIZANDO HOLT-WINTERS E REDE NEURAL NÃO
LINEAR AUTOREGRESSIVA COM ENTRADAS EXÓGENAS (NARX) PARA
PREVISÃO DA VELOCIDADE DO VENTO**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental - PPG.EGPSA, do Instituto de Tecnologia e Educação Galileo da Amazônia- ITEGAM, como parte dos requisitos necessários à obtenção do título de Mestre.

Orientador: Dr. David Barbosa de Alencar

**MANAUS – AM
2021**

RICARDO SILVA PARENTE

**MODELO HÍBRIDO UTILIZANDO HOLT-WINTERS E REDE NEURAL NÃO
LINEAR AUTOREGRESSIVA COM ENTRADAS EXÓGENAS (NARX) PARA
PREVISÃO DA VELOCIDADE DO VENTO**

Esta dissertação foi julgada e aprovada para a obtenção do título de Mestre do Programa de Pós-Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental do Instituto de Tecnologia e Educação Galileo da Amazônia – ITEGAM.

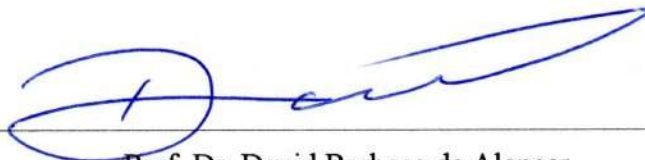
Manaus-AM, 27 de Julho de 2021.



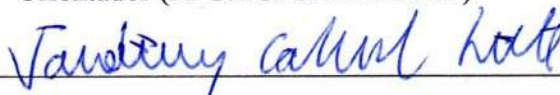
Prof. Dr. Jandecy Cabral Leite

Coordenador do PPG.EGPSA - ITEGAM

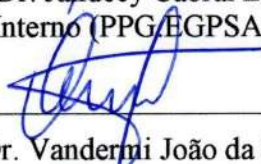
BANCA EXAMINADORA



Prof. Dr. David Barbosa de Alencar
Orientador (PPG.EGPSA/ITEGAM)



Prof. Dr. Jandecy Cabral Leite
Examinador Interno (PPG.EGPSA/ITEGAM)



Prof. Dr. Vanderlei João da Silva
Examinador Externo (UFAM)

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Biblioteca do ITEGAM

Parente, Ricardo Silva, 2021 - Modelo híbrido utilizando Holt-Winters e Rede Neural não Linear AutoRegressiva com Entradas Exógenas (NARX) para previsão da velocidade do vento / Ricardo Silva Parente - 2021. 120 f., il: Colorido

Orientador: Dr. David Barbosa de Alencar

Dissertação: Instituto de Tecnologia e Educação Galileo da Amazônia, Programa de Pós Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental (PPG-EGPSA), Manaus - AM, 2021.

1. Previsão da velocidade do vento 2. Modelo híbrido 3. Holt-Winters 4. Energia eólica 5. Rede Neural Artificial

CDD - 1001.ed.2021.1

AGRADECIMENTOS

Os agradecimentos estão voltados primeiramente a Deus que me possibilitou está onde estou, a toda minha família que me deu apoio incondicional para que mim conclui-se este mestrado profissional, especialmente para minha Mãe Rosenilde Costa da Silva Parente que além de me dar a vida me deu educação, me moldando para grandes conquistas, sendo o mestrado uma delas.

Agradeço aos integrantes da minha família que não poderia deixar de mencionar, ao meu Pai José de Ribamar de Sousa Parente, meu irmão Rodrigo Silva Parente, um homem de valor e juízo que me apoiou e sempre esteve do meu lado nas alegrias e adversidades. A minha Vó Benedita Costa da Silva que sempre me deu conselhos positivos para sempre acreditar e nunca desistir, não importando os desafios encontrados. A minha tia Djacy Costa da Silva e meu tio José Iramar dos Santos da Conceição que me acolheram e me incentivaram a sempre buscar o conhecimento. Aos meus primos Yuri Costa da Conceição e Luís Otávio da Conceição que sempre depositaram confiança e alegria no decorrer desta linda caminhada de estudos árduos.

Agradeço aos meus amigos Renildo Leite Silva, Raone Henrique Ferreira Castro, Matheus Rabelo Moreira, Adrielle Steffani de Araújo, Bilga Costa Pereira, Jorge Hudson, Willian Alessandro, Elivelton Bastos, Cristina Cardoso Lima, Erisvan Chagas, Paulo Ricardo, Gustavo Amorim, Márcio Santos, Reis Silva, Lázaro Silva, Marilene Leite Silva, Camila Jorge Pires, Renata Santos, Marciano Barros de Faria, Welson de Freitas Silva, Rosemere Paes, Emerson Lopes, Antônio Elson, Rafael Chaves e Odailton Pereira, que sempre acreditaram no meu potencial e sempre estiveram e estão ao meu lado. Aos meus colegas e amigos Ítalo Rodrigo Soares Silva e Paulo Oliveira Siqueira Junior que são excelentes profissionais e amigos, no qual me deram um grande apoio na trajetória de graduação e mestrado.

Agradeço ao meu orientador, Professor Dr. David Barbosa de Alencar que sempre me apoiou e me passou conhecimento e sabedoria para o mestrado e para a vida. Aos professores Dr. Jorge Almeida de Brito Júnior e Dr. Jandecy Cabral Leite, que foram exemplo de disciplina e me ajudaram a crescer intelectualmente e a ter melhores tomadas de decisão.

Agradeço em último lugar, mas não menos importante ao Instituto de Tecnologia e Educação Galileo da Amazônia (ITEGAM) e ao Programa de Pós-Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental (PPG-EGPSA) pela oportunidade dada.

Epígrafe

“A verdade é filha do tempo, e não da autoridade”

Galileo Galilei

Dedicatória

Dedico a Deus, minha Mãe Rosenilde Costa da Silva Parente, meu irmão Rodrigo Silva Parente e a toda minha família e amigos.

RESUMO

PARENTE, Ricardo Silva. **MODELO HÍBRIDO UTILIZANDO HOLT-WINTERS E REDE NEURAL NÃO LINEAR AUTOREGRESSIVA COM ENTRADAS EXÓGENAS (NARX) PARA PREVISÃO DA VELOCIDADE DO VENTO**. 2021. p. 120. Dissertação do Programa de Pós-Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental (PPG-EGPSA), Instituto de Tecnologia e Educação Galileo da Amazônia (ITEGAM), Manaus, 2021.

A matriz energética eólica vem aumentando gradativamente nos últimos anos e sua importância para a indústria de energia renovável é cada vez mais atrelada aos benefícios em relação ao meio ambiente, com esta crescente da matriz energética as pesquisas em torno da geração de energia eólica também vem aumentando, sendo uma das vertentes a previsão da velocidade do vento, pois com isso é possível prever a geração de energia eólica e diminuir a taxa de erros em tomadas de decisões na indústria de geração de eletricidade por meio da matriz eólica. Tendo em vista a problemática de tomadas de decisões e imprevisibilidade da velocidade do vento, o presente trabalho tem o objetivo de desenvolver um modelo híbrido para a previsão da velocidade do vento que pode ser utilizada na geração de energia eólica, baseado em Suavização Exponencial de Holt-Winters (HW) e Rede Neural Não Linear AutoRegressiva com Entradas Exógenas (NARX). Nos materiais e métodos foi usado a base de dados do projeto SONDA (Sistema de Organização Nacional de Dados Ambientais) organizado pelo INPE (Instituto Nacional de Pesquisas Espaciais), no qual optou-se por utilizar os dados anemométricos da estação de Brasília – BRB e Petrolina – PTR, onde foram usados dados dos anos de fevereiro de 2005 a março de 2019 da estação de BRB para treinamento, validação e testes, e de janeiro de 2006 a dezembro de 2015 da estação de PTR para simulações do HW, NARX e o modelo proposto. Os resultados obtidos com o modelo híbrido proposto HW-NARX foram comparados com os algoritmos de previsão de series temporais com sazonalidade HW e NARX, no qual o modelo proposto conseguiu atingir resultados de performance e previsibilidade melhores que o HW e o NARX para os horizontes de tempo de ultra-curto prazo, médio prazo e longo prazo, no qual foram utilizados como parâmetros de performance os erros MSE, RMSE e MAPE.

Palavras-Chave: Previsão da velocidade do vento, Modelo híbrido, Holt-Winters, Energia eólica, Rede Neural Artificial.

ABSTRACT

PARENTE, Ricardo Silva. **MODELO HÍBRIDO UTILIZANDO HOLT-WINTERS E REDE NEURAL NÃO LINEAR AUTOREGRESSIVA COM ENTRADAS EXÓGENAS (NARX) PARA PREVISÃO DA VELOCIDADE DO VENTO**. 2021. p. 120. Dissertação do Programa de Pós-Graduação em Engenharia, Gestão de Processos, Sistemas e Ambiental (PPG-EGPSA), Instituto de Tecnologia e Educação Galileo da Amazônia (ITEGAM), Manaus, 2021.

The wind energy matrix is gradually increasing in recent years and its importance for the renewable energy industry is increasingly linked to the benefits in relation to the environment, with this growing energy matrix the research around the wind power generation is also increasing, and one of the strands is the wind speed prediction, because with this it is possible to predict the wind power generation and decrease the error rate in decision making in the industry of electricity generation through wind power matrix. Considering the problem of decision making and the unpredictability of wind speed, this paper aims to develop a hybrid model for wind speed prediction and consequently wind power generation, based on Holt-Winters Exponential Smoothing and Nonlinear Auto-Regressive Neural Network with Exogenous Inputs (NARX). In the materials and methods, the database of the SONDA project (System of National Organization of Environmental Data) organized by INPE (National Institute for Space Research) was used, in which it was chosen to use the anemometric data from the station of Brasilia - BRB and Petrolina - PTR, where data from the years February 2005 to March 2019 of the BRB station were used for training, validation and testing, and from January 2006 to December 2015 of the PTR station for simulations of the HW, NARX and proposed model. The results obtained with the proposed hybrid HW-NARX model were compared with the HW and NARX seasonal time series forecasting algorithms, in which the proposed model was able to achieve better performance and predictability results than HW and NARX for the ultra-short-term, medium-term, and long-term time horizons.

Keywords: Wind speed forecast, Hybrid model, Holt-Winters, Wind energy, Artificial Neural Network.

LISTA DE FIGURAS

Figura 2.1 - Comparação entre neurônios biológicos e artificiais.....	39
Figura 2.2 - Arquitetura NARX.....	40
Figura 2.3 - Células de Memória.....	41
Figura 3.1 - Fluxograma de validação de dados SONDA.....	45
Figura 3.2 - Arquitetura e configurações utilizadas na rede NARX.....	49
Figura 3.3 - Divisão de dados para o modelo NARX.....	49
Figura 3.4 - Comportamento das variáveis de entrada ao longo de 10 anos.....	53
Figura 3.5 - Comportamento da Velocidade do Vento ao longo de 10 anos.....	54
Figura 4.1 - Arquitetura do modelo híbrido proposto HW-NARX.....	59
Figura 4.2 - Fluxograma do algoritmo proposto HW-NARX.....	61
Figura 4.3 - Configurações da Rede Neural NARX.....	65

LISTA DE GRÁFICOS

Gráfico 2.1 - Comparativo de fontes não Renováveis com Renováveis (2009-2018).	26
Gráfico 2.2 - Geração de energia por fontes não renováveis do ano de 2018.	26
Gráfico 2.3 - Geração de energia por fontes renováveis do ano de 2018.	27
Gráfico 2.4 - Fluxo de geração de energia hidráulica no cenário brasileiro (2009-2018)..	30
Gráfico 2.5 - Fluxo de geração de energia eólica no Brasil (2009-2018).....	31
Gráfico 4.1 - Comparativo de regressão do LM, BS e SCG (base de dados de BRB).	56
Gráfico 4.2 - Comparativo de erros MSE do LM, BS e SCG (base de dados de BRB).	57
Gráfico 4.3 - Comparativo de erros RMSE do LM, BS e SCG (base de dados de BRB)..	57
Gráfico 4.4 - Sazonalidade do Horizonte de 1 Semana (Base de dados de PTR).	63
Gráfico 4.5 - Comparativo de regressão entre o modelo NARX e o modelo proposto.	67
Gráfico 4.6 - Comparativo de épocas entre o modelo NARX e o modelo proposto.	68
Gráfico 4.7 - Comparativo de erros (Horizonte de 10 minutos 5 passos à frente).	69
Gráfico 4.8 - Comparativo de previsão (Horizonte de 10 minutos 5 passos à frente).....	70
Gráfico 4.9 - Comparativo de erros (Horizonte de 10 minutos 10 passos à frente).	71
Gráfico 4.10 - Comparativo de previsão (Horizonte de 10 minutos 10 passos à frente)....	72
Gráfico 4.11 - Comparativo de erros (Horizonte de 10 minutos 30 passos à frente).	73
Gráfico 4.12 - Comparativo de previsão (Horizonte de 10 minutos 30 passos à frente)....	74
Gráfico 4.13 - Comparativo de erros (Horizonte de 1 hora 5 passos à frente).	75
Gráfico 4.14 - Comparativo de previsão (Horizonte de 1 hora 5 passos à frente).	76
Gráfico 4.15 - Comparativo de erros (Horizonte de 1 hora 10 passos à frente).	77
Gráfico 4.16 - Comparativo de previsão (Horizonte de 1 hora 10 passos à frente).	78
Gráfico 4.17 - Comparativo de erros (Horizonte de 1 hora 30 passos à frente).	79
Gráfico 4.18 - Comparativo de previsão (Horizonte de 1 hora 30 passos à frente).	80
Gráfico 4.19 - Comparativo de erros (Horizonte de 1 dia 5 passos à frente).	82
Gráfico 4.20 - Comparativo de previsão (Horizonte de 1 dia 5 passos à frente).....	83
Gráfico 4.21 - Comparativo de erros (Horizonte de 1 dia 10 passos à frente).	84
Gráfico 4.22 - Comparativo de previsão (Horizonte de 1 dia 10 passos à frente).....	85
Gráfico 4.23 - Comparativo de erros (Horizonte de 1 dia 30 passos à frente).	86
Gráfico 4.24 - Comparativo de previsão (Horizonte de 1 dia 30 passos à frente).....	87
Gráfico 4.25 - Comparativo de erros (Horizonte de 1 semana 5 passos à frente).	89
Gráfico 4.26 - Comparativo de previsão (Horizonte de 1 semana 5 passos à frente).....	90

Gráfico 4.27 - Comparativo de erros (Horizonte de 1 semana 10 passos à frente).	91
Gráfico 4.28 - Comparativo de previsão (Horizonte de 1 semana 10 passos à frente).....	92
Gráfico 4.29 - Comparativo de erros (Horizonte de 1 semana 30 passos à frente).	93
Gráfico 4.30 - Comparativo de previsão (Horizonte de 1 semana 30 passos à frente).....	94

LISTA DE TABELAS

Tabela 2.1 - Matriz energética brasileira (2009-2018).	25
Tabela 2.2 - Funções de ativação.....	43
Tabela 3.1 - Quantidade de dados utilizados na base BRB.	50
Tabela 3.2 - Amostra de dados de BRB.	50
Tabela 3.3 - Quantidade de dados utilizados na base de PTR.	51
Tabela 3.4 - Amostra de dados de PTR.	52
Tabela 3.5 - Mínimos, máximos e médias da base de dados de PTR.....	52
Tabela 4.1 - Resultado dos algoritmos de treinamento para o horizonte de 1 dia 5 passos à frente.....	56
Tabela 4.2 - Parâmetros utilizados para suavização das variáveis.	66

LISTA DE QUADROS

Quadro 1.1 - Horizontes de previsão da velocidade do vento e suas aplicações.	20
Quadro 1.2 - Algoritmos híbridos para a previsão de séries temporais.	21
Quadro 2.1 - Incentivos para geração de energia fotovoltaica no Brasil.	28
Quadro 2.2 - Incentivos para geração de energia fotovoltaica no mundo.....	29
Quadro 2.3 - Trabalhos relacionados à previsão da velocidade do vento com ARIMA....	35
Quadro 2.4 - Trabalhos relacionados à previsão de séries temporais com SARIMA.....	35
Quadro 3.1 - Características avaliadas no processo de validação dos dados pela SONDA.	47
Quadro 3.2 - Setup de configurações do notebook utilizado para os experimentos.	50
Quadro 4.1 - Estações encontradas no projeto SONDA.	58
Quadro 4.2 - Melhor algoritmo entre os horizontes analisados.	95
Quadro 4.3 - Comparativo de trabalhos relacionados (Algoritmos Híbridos).	96

LISTA DE SIGLAS E ABREVIATURAS

ARIMA	<i>Autoregressive Integrated Moving Average</i>
ARIMAX	<i>AutoRegressive Integrated Moving Average Exogenous Inputs</i>
ACF	<i>AutoCorrelation Functions</i>
ANEEL	Agência Nacional de Energia Elétrica
ANN	<i>Artificial Neural Network</i>
AR	Auto Regressivo
BJD	Belo Jardim
BRB	Brasília
BS	<i>Bayesian Regularization</i>
BSRN	<i>Baseline Surface Radiation Network</i>
CAI	Caicó
CBA	Cuiabá
CGR	Campo Grande
CHP	Chapecó
CM	Células de Memória
CO₂	Dióxido de Carbono
CPA	Cachoeira Paulista
CSA	<i>Cooperation Search Algorithm</i>
CTB	Curitiba
ED	Evolução Diferencial
En4DVAR	Previsão por Conjuntos e Cálculo Variacional Quadri-Dimensional
EPE	Empresa de Pesquisa Energética
EUA	Estados Unidos da América
FGTS	Fundo de Garantia do Tempo de Serviço
FKR	Filtro de Kalman Recorrente
FLN	Florianópolis
GARCH	<i>Generalized AutoRegressive Conditional Heteroskedasticity</i>
GEE	Gases de Efeito Estufa
GPR	<i>Gaussian Process Regression</i>
GWh	<i>Gigawatts por hora</i>
GWO	<i>Grey Wolf Optimizer</i>
HW	<i>Holt-Winters</i>
HW-NARX	<i>Holt-Winters + Nonlinear AutoRegressive Exogenous</i>
I	Integrado
IA	Inteligência Artificial
IRBFNN-EF	<i>Improved Radial Basis Function Neural Network with an Error Feedback</i>
INPE	Instituto Nacional de Pesquisas Espaciais
JOI	Joinville
LM	<i>Levenberg-Marquardt</i>
LSTM	<i>Long Short-Term Memory</i>
MA	Média Móvel
MAPE	<i>Mean Absolute Percentage Erro</i>
MSE	<i>Mean Square Error</i>
NARX	<i>Nonlinear AutoRegressive Exogenous</i>
NAT	Natal
NS	Neutrosóficos
ORN	Ourinhos

PACF	<i>Partial AutoCorrelation Function</i>
PMA	Palmas
PSHONN	<i>Pi-Sigma Higher Order Neural Network</i>
PSO	<i>Particle Swarm Optimization</i>
PTR	Petrolina
RAM	<i>Random Access Memory</i>
ReLU	Unidade Linear Retificada
REN	Resolução Normativa
RLM	Rolim de Moura
RMSE	<i>Root Mean Squared Error</i>
RNA	Redes Neurais Artificiais
SARIMA	<i>Seasonal AutoRegressive Integrated Moving Average</i>
SBR	Sombrio
SCG	<i>Scaled Conjugate Gradient</i>
SCR	São João do Cariri
SG	Sigmoide
SLZ	São Luiz
SMS	São Martinho da Serra
SONDA	Sistema de Organização Nacional de Dados Ambientais
SSD	<i>Solid State Drives</i>
TanH	Tangente Hiperbólica
TDRG	<i>Top-Down Relevant Feature Search</i>
TRI	Triunfo
WRF	<i>Weather Research and Forecasting Model</i>

SUMÁRIO

CAPÍTULO 1	19
1 INTRODUÇÃO	19
1.1 IDENTIFICAÇÃO E JUSTIFICATIVA DO PROBLEMA DE PESQUISA	20
1.1.1 Contribuição e Relevância do Estudo	21
1.1.2 Delimitação da Pesquisa	22
1.2 OBJETIVOS	23
1.2.1 Geral	23
1.2.2 Específicos	23
1.3 ESCOPO DO TRABALHO	23
CAPÍTULO 2	25
2 REVISÃO DA LITERATURA	25
2.1 MATRIZ ENERGÉTICA	25
2.1.1 Geração de Energia Fotovoltaica	27
2.1.2 Geração de Energia Hidráulica	29
2.1.3 Geração de Energia Eólica	30
2.2 SÉRIES TEMPORAIS	32
2.3 MODELOS DE PREVISÃO	33
2.3.1 ARIMA	33
2.3.2 SARIMA	35
2.3.3 Modelo Holt-Winters	37
2.3.4 Redes Neurais Artificiais	39
2.3.5 Algoritmos de Treinamento	41
2.3.5.1 Levenberg-Marquardt	41
2.3.5.2 Bayesian Regularization	42
2.3.5.3 Scaled Conjugate Gradient	42
2.3.6 Funções de Ativação	43

CAPÍTULO 3	44
3 MATERIAIS E MÉTODOS	44
3.1 MATERIAIS	44
3.1.1 Normalização de Dados	47
3.1.2 Implementação do Algoritmo Híbrido	47
3.1.3 Erros	47
3.2 MÉTODOS	48
3.2.1 Arquitetura Utilizada da RNA (NARX)	48
3.2.2 Primeira Etapa de Testes	50
3.2.3 Segunda Etapa de Testes	51
CAPÍTULO 4	55
4 RESULTADOS E DISCUSSÕES	55
4.1 TESTES DA PRIMEIRA ETAPA: ENCONTRAR O MELHOR ALGORITMO DE TREINAMENTO PARA O MODELO NARX (ESTAÇÃO DE BRB).....	55
4.2 MODELO PROPOSTO HW-NARX	59
4.2.1 Fluxograma do Modelo Proposto HW-NARX	60
4.3 Testes da Segunda Etapa: Modelo Híbrido Proposto HW-NARX (Estação de PTR)...	65
4.3.1 Análise do Comparativo de Erros de Performance e Previsibilidade	68
4.3.1.1 Horizonte de 10 Minutos	68
4.3.1.2 Horizonte de 1 Hora	74
4.3.1.3 Horizonte de 1 Dia	81
4.3.1.4 Horizonte de 1 Semana	88
CAPÍTULO 5	97
5 CONCLUSÕES E SUGESTÕES	97
5.1 CONCLUSÕES	97
5.2 SUGESTÕES PARA TRABALHOS FUTUROS.....	98

CAPÍTULO 1

1 INTRODUÇÃO

A energia elétrica é importantíssima e há algumas formas de gerá-la, entre as quais se destacam as renováveis, sendo elas a solar e eólica, esta última com uma vasta aplicação no Brasil por ser um país de dimensão continental e apresentar grandes incidências de ventos, principalmente no litoral nordestino (DA SILVA PEREIRA, 2021).

A matriz energética renovável/alternativa do Brasil vem crescendo no passar dos anos (SANTANA *et al.*, 2020; BARBOSA DE ALENCAR *et al.*, 2017). Segundo Silva *et al.* (2017), há quatro fatores primordiais para este crescimento, que são: Característica do vento no país, políticas de incentivo a geração de energia eólica, competitividade gerada pelo setor eólico e consequentemente preços competitivos em relação a fontes não renováveis.

Outro fator que torna a geração de energia eólica uma fonte em alto crescimento no Brasil e no mundo é a questão do impacto ambiental causado e a auto sustentabilidade. Tendo em vista esses aspectos que impactam diretamente na matriz energética como um todo, é de extrema importância prever a velocidade do vento para um determinado horizonte de tempo, pois sabendo-se a velocidade do vento é possível calcular a geração de energia em um intervalo de tempo no futuro, evitando assim a geração de energia elétrica por fontes que prejudicam o meio ambiente mais fortemente.

Existem alguns modelos de previsão que podem ser encontrados na literatura, sendo eles meteorológicos, estatísticos, computacionais e híbridos, no qual os híbridos são a junção de dois ou mais algoritmos de tipos diferentes (CAMELO *et al.*, 2017), por exemplo: computacional e estatístico. Esses modelos híbridos são mais eficientes em termo de acurácia do que algoritmos que utilizam apenas uma técnica (LIU, TIAN e LI, 2012). Contudo, os algoritmos híbridos são desenvolvidos regularmente a fim de alcançar cada vez mais uma acurácia e confiabilidade mais perto de 100%.

A previsão de energia eólica por meio da previsibilidade da velocidade do vento se torna necessária para que haja um bom planejamento dos parques eólicos, incluindo manutenções nas redes e parques eólicos, despacho das unidades geradoras, venda de energia, atendimento da carga e outros benefícios (BARBOSA DE ALENCAR *et al.*, 2017; BOUERES *et al.*, 2020), ao mesmo tempo que é complexo prever com uma boa acurácia devido à instabilidade, sazonalidade, não linearidade e rajadas de ventos abruptas (DONG, SUN e LI, 2017). Assim, o

intuito de prever a velocidade do vento com uma maior performance pode ser considerado primordial para uma evolução ainda maior da geração de energia eólica no Brasil e no mundo.

1.1 IDENTIFICAÇÃO E JUSTIFICATIVA DO PROBLEMA DE PESQUISA

Atualmente a matriz energética eólica está aumentando constantemente no passar dos anos, no qual sua utilização é muito benéfica em relação ao meio ambiente e a questão financeira (CREPALDI, AMOROSO e ANDO, 2018; IPAKCHI e ALBUYEH, 2009), com este aumento o mercado de geração de energia eólica vem se fortalecendo e ficando mais atrativo aos empreendedores (DA SILVA PEREIRA, 2021).

Um dos problemas que ocorre na geração de energia eólica é sua imprevisibilidade, isso ocorre devido a intermitência do comportamento dos ventos (GERTRUDES, 2020; BOUERES *et al.*, 2020), com isso não se sabe ao certo a quantidade de energia a ser gerada em determinado horizonte de tempo, prejudicando o planejamento de despacho de energia.

Conforme pode ser observado no Quadro 1.1, que possui os horizontes de tempo utilizados para a previsão, o período correspondente de cada horizonte e as aplicações para a previsão de cada horizonte, é possível notar que para cada horizonte de previsão há uma determinada aplicação na indústria de geração de energia eólica.

Quadro 1.1 - Horizontes de previsão da velocidade do vento e suas aplicações.

Horizonte	Período	Aplicações
Ultracurto Prazo	10 minutos a 1 hora à frente	- Ações de regulação do controle de turbina eólica; - Compensação do mercado de eletricidade.
Curto Prazo	1 hora a 24 horas à frente	- Planejamento econômico de despacho de carga; - Decisões razoáveis de carga (incremento/diminuição).
Médio Prazo	1 dia a 7 dias à frente	- Gerador de Decisões Online/Offline (Providências para manutenção); - Decisões de Compromisso da Unidade.
Longo Prazo	1 semana a anos à frente	- Programação de manutenção para obter o custo operacional ideal; - O Estudo de Viabilidade para Projeto do Parque Eólico.

Fonte: ZHAO, WANG e LI (2011).

Para a minimização desta problemática é realizado a previsão da velocidade do vento para diferentes horizontes de tempo, a fim de melhorar a previsibilidade da geração de energia, ajudando a tomada de decisões dos operadores (CAMELO *et al.*, 2017).

Na literatura são encontrados vários modelos de previsão da velocidade do vento e alguns deles híbridos, como poder ser visto nos trabalhos elencados no Quadro 1.2.

Quadro 1.2 - Algoritmos híbridos para a previsão de séries temporais.

Autores	Técnicas
(SINGH, 2020)	Teoria dos conjuntos neutrosóficos (NS) com algoritmo <i>Particle Swarm Optimization</i> (PSO).
(JALLAL <i>et al.</i> , 2020)	Inferência <i>Neuro-Fuzzy</i> adaptativo com <i>Firefly</i> de diferença de gênero.
(ALY, 2020)	<i>Wavelet</i> , RNA, Séries Temporais com Filtro de Kalman Recorrente (FKR).
(PATTANAYAK, BEHERA e PANIGRAHI, 2020)	Evolução Diferencial (ED) com <i>Pi-Sigma Higher Order Neural Network</i> (PSHONN).
(ALTAN, KARASU e ZIO, 2021)	<i>Long Short-Term Memory</i> (LSTM) com <i>Grey Wolf Optimizer</i> (GWO).
(CAMELO <i>et al.</i> , 2017)	<i>Auto-Regressive Integrated Moving Average</i> (ARIMA) com RNA, HW com RNA.
(FENG e NIU, 2021)	RNA com algoritmo de treinamento <i>Cooperation Search Algorithm</i> (CSA)

Fonte: AUTOR (2021).

No geral algoritmos híbridos apresentam menores taxas de erros e conseqüentemente uma melhor previsibilidade do que algoritmos isolados (ALTAN, KARASU e ZIO, 2021), tendo como ponto de partida este fato, o desenvolvimento de novos modelos híbridos que consigam ter uma previsibilidade mais próxima de 100% pode otimizar o planejamento e aumentar a confiabilidade de geração de energia eólica.

Logo o presente trabalho se justifica pela relevância que a matriz energética estudada tem no cenário brasileiro e exterior (DA SILVA, ALVES E RAMALHO, 2020; DA SILVA *et al.*, 2020), além da previsão da velocidade do vento ser um fator de extrema importância para fazer o planejamento da quantidade de energia elétrica a ser gerada nos próximos períodos de tempo, conforme Quadro 1.1.

1.1.1 Contribuição e Relevância do Estudo

O presente trabalho tem como contribuição, o desenvolvimento de um modelo híbrido, capaz de prever a velocidade do vento a um determinado horizonte de tempo e certa quantidade de passos à frente, assim proporcionando um melhor planejamento e utilização da energia eólica. Entre os benefícios do trabalho podem-se destacar os seguintes:

- Possibilidade de aplicar o algoritmo híbrido proposto para o planejamento de manutenções na rede elétrica dos parques eólicos.
- Razoabilidade de geração de energia eólica e outras matrizes energéticas.
- Prever a velocidade do vento por meio computacional para diferentes horizontes de tempo.
- Melhor aproveitamento da energia eólica.
- Otimizar o processo de análise de localidades para instalação de parques eólicos.

Com a utilização de um modelo híbrido espera-se que aumente a confiabilidade da previsão dos ventos e que seja cada vez mais próxima da realidade, trazendo benefícios na indústria de geração de energia elétrica. Desta forma tendo em vista a problemática de previsão da geração de energia eólica que gira em torno da imprevisibilidade dos ventos, o presente estudo contribui com um algoritmo híbrido formado pelo HW+NARX na aplicação de previsão da velocidade do vento, tal algoritmo não foi encontrado na literatura para a previsão da velocidade do vento, o algoritmo que mais se aproxima do modelo proposto é o HW+RNA de Camelo *et al.*, (2017) mostrado no Quadro 1.2.

1.1.2 Delimitação da Pesquisa

O presente estudo está limitado a desenvolver um modelo híbrido de previsão, utilizando um modelo estatístico (HW) e outro computacional (NARX), para a previsão da velocidade do vento e conseqüentemente comparar com os modelos HW e NARX existentes na literatura, permitindo assim a avaliação da acurácia do modelo proposto. A previsão da velocidade do vento está limitada aos horizontes de tempo de 10 minutos 5, 10 e 30 passos à frente, horizonte de 1 hora 5, 10 e 30 passos à frente, horizonte de 1 dia 5, 10 e 30 passos à frente e o horizonte de 1 semana 5, 10 e 30 passos à frente.

O trabalho se limita em prever a velocidade do vento, no qual pode ser utilizado para melhores tomadas de decisões no setor de geração de energia eólica, não é o objetivo do trabalho prever a geração de energia eólica de uma determinada turbina de um aerogerador.

Como base de dados será utilizado os dados coletados pelo projeto SONDA da estação eólica de BRB. Esta base de dados foi selecionada devido a sua quantidade de registros coletados a cada minuto ao longo de 15 anos, outro fator da escolha da base de dados é a disponibilidade, sendo os dados públicos. A base de dados é utilizada na primeira etapa de testes, efetuados para encontrar a melhor configuração da rede neural recorrente NARX.

Para a segunda etapa de testes é utilizada a base de dados de PTR dos anos de 2006 a 2015, também do projeto SONDA, os dados dessa base são utilizados para efetuar as simulações dos modelos HW, NARX e do modelo híbrido proposto HW-NARX.

1.2 OBJETIVOS

1.2.1 Geral

Desenvolver um modelo híbrido utilizando a Suavização Exponencial de Holt-Winters (HW) e a Rede Neural não Linear Autoregressiva com Entradas Exógenas (NARX), a fim de prever a velocidade do vento para melhores tomadas de decisões, impactando no aumento da confiabilidade da geração de energia eólica.

1.2.2 Específicos

- Elaborar e apresentar uma revisão dos modelos de previsão de séries temporais como: ARIMA, SARIMA, HW, Redes Neurais Artificiais (RNA) e NARX;
- Identificar e selecionar a base de dados a ser utilizada para treinamento, validação e testes do modelo a ser desenvolvido;
- Desenvolver e encontrar as melhores configurações da Rede Neural NARX (Número de camadas ocultas, número de neurônios das camadas ocultas e algoritmo de treinamento) do modelo híbrido proposto;
- Comparar a performance do modelo híbrido proposto com os modelos HW e NARX.

1.3 ESCOPO DO TRABALHO

A presente dissertação é estruturada da seguinte forma:

- **Capítulo 1:** Neste Capítulo foi mostrado a introdução sobre o tema, identificação e justificativa do problema, os objetivos, contribuição e relevância do estudo e delimitação da pesquisa;
- **Capítulo 2:** Neste capítulo é apresentado uma revisão de literatura sobre o tema abordado, dividido em duas categorias bases, matriz energética e modelos de previsão;
- **Capítulo 3:** Neste capítulo são apresentados os procedimentos metodológicos da pesquisa, os materiais utilizados e métodos realizados para chegar nos resultados e conclusões;

- **Capítulo 4:** Neste capítulo é apresentado o algoritmo híbrido proposto HW-NARX, além do comparativo dos resultados de performance alcançados pelos modelos de previsão HW, NARX e o modelo proposto;
- **Capítulo 5:** Por fim são apresentadas as conclusões e algumas sugestões para trabalhos futuros.

CAPÍTULO 2

2 REVISÃO DA LITERATURA

2.1 MATRIZ ENERGÉTICA

A necessidade do homem por energia elétrica vem aumentando gradativamente conforme o tempo, entre as principais funções básicas estão a iluminação, aquecimento, comunicação e transporte (LETCHER e WILLIAMSON, 2004). Devido a tal aumento de necessidade por energia elétrica e a degradação do meio ambiente, a matriz energética foi elevando o nível de diversificação (DOS SANTOS, DE SÁ RODRIGUES e CARNIELLO, 2021; PAIM *et al.*, 2019). Outro fator preponderante para a diversificação da matriz energética no Brasil nas últimas duas décadas (2000-2020) foi a escassez de água, que impacta diretamente na geração de energia elétrica, causando insuficiência de oferta e demanda (GOMES *et al.*, 2018).

Conforme pode ser observado na Tabela 2.1, a matriz energética com maior percentual com 46,6% é o conjunto de Petróleo, Gás natural e derivados, enquanto que o menor é a fonte energética solar com 0,1% de participação.

Tabela 2.1 - Matriz energética brasileira (2009-2018).

FONTES	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018
PETRÓLEO, GÁS NATURAL E DERIVADOS	46,7	48,1	48,8	50,8	52,1	52,9	51,0	48,9	49,2	46,9
CARVÃO MINERAL E DERIVADOS	4,6	5,4	5,7	5,4	5,6	5,7	5,9	5,5	5,7	5,8
HIDRÁULICA E ELETRICIDADE	15,2	14,0	14,7	13,8	12,5	11,5	11,3	12,6	11,9	12,6
LENHA E CARVÃO VEGETAL	10,1	9,7	9,5	9,1	8,3	8,2	8,3	8,0	8,2	8,4
PRODUTOS DA CANA	18,1	17,5	15,7	15,4	16,1	15,8	16,9	17,4	17,0	17,4
EÓLICA	0,0	0,1	0,1	0,2	0,2	0,3	0,6	1,0	1,2	1,4
SOLAR	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,1
OUTRAS¹	5,2	5,2	5,5	5,4	5,3	5,6	6,0	6,6	6,7	7,4
TOTAL	100	100	100	100	100	100	100	100	100	100

*Todos os valores estão em porcentagem (%).


¹Inclui Outras Fontes Primárias Renováveis e Urânio.

Fonte: EMPRESA DE PESQUISA ENERGÉTICA - EPE (2019).

No Gráfico 2.1 é exposto um comparativo entre as energias renováveis e as não renováveis nos anos de 2009 a 2018, no qual é possível notar que desde de 2009 as energias geradas por fontes renováveis são superiores a quantidade gerada pelas não renováveis.

Fazendo um cálculo básico de porcentagem, obtemos que 495.290 que foi a potência gerada pelas energias renováveis em 2018 é equivalente a aproximadamente 82,36% da energia total gerada.


Gráfico 2.1 - Comparativo de fontes não Renováveis com Renováveis (2009-2018).



Fonte: Adaptado de EMPRESA DE PESQUISA ENERGÉTICA - EPE (2019).

No Gráfico 2.2 no qual é apresentado as fontes não renováveis de geração de energia elétrica, pode-se observar que o Gás natural teve a maior quantidade de *Gigawatts* por hora (GWh) gerados, enquanto que Gás de coqueria teve a menor quantidade com 1.620 GWh gerados. Vale ressaltar que o total GWh produzido pelas fontes não renováveis no ano de 2018 é equivalente a 106.107 GWh.


Gráfico 2.2 - Geração de energia por fontes não renováveis do ano de 2018.



Fonte: Adaptado de EMPRESA DE PESQUISA ENERGÉTICA - EPE (2019).

O Gráfico 2.3 exibe os dados de geração de eletricidade por meio das fontes renováveis, a geração de energia por meio da fonte Hidráulica teve o maior número com 388.971 de GWh, enquanto que o Biodiesel produziu menos eletricidade com 391 GWh gerados no ano de 2018. Somando todas as fontes renováveis se chega ao resultado de 495.290 GWh gerados no ano de 2018, somando ao total gerado pelas fontes não renováveis chega-se ao total gerado no todo com base em todas as fontes de geração de energia do país, tendo sido gerado 601.396 GWh.

Gráfico 2.3 - Geração de energia por fontes renováveis do ano de 2018.



Fonte: Adaptado de EMPRESA DE PESQUISA ENERGÉTICA - EPE (2019).

Ao passar dos anos a matriz energética renovável apresenta uma maior participação no mercado de energia elétrica no mundo, já que são uma solução para diminuição de problemas relacionados à emissão de gases prejudiciais a atmosfera, causando o efeito estufa (SANTOS AZA e ECHEVERRY CORREDOR, 2021).

Com a grande demanda de energia elétrica surge a necessidade de renovação da matriz energética e isso acontece com o incremento de energias renováveis e limpas (DOS SANTOS, DE SÁ RODRIGUES e CARNIELLO, 2021; BARBOSA, 2021). Sendo as principais formas de geração de energia renovável e limpa a energia fotovoltaica, hidráulica e eólica.

2.1.1 Geração de Energia Fotovoltaica

Em relação a energia fotovoltaica no Brasil, o país detém características privilegiadas que possibilitam a inserção e aumento desta matriz energética, como raios solares intensos

durante boa parte do dia e em várias regiões do país, além de possuir grandes reservas de quartzo de qualidade, material este que é utilizado para a fabricação de células fotovoltaicas, porém mesmo com estas características favoráveis a energia fotovoltaica, ainda é pouco explorada devido à falta de incentivos (RELLA, 2017; DA FONTOURA, RABUSKE e FRIEDRICH, 2018; DOS SANTOS CARSTENS e DA CUNHA, 2019).

A partir do ano de 2012 houve algumas iniciativas para o aumento de geração de energia elétrica por meio de sistemas fotovoltaicos, o Quadro 2.1 mostra tais iniciativas elencadas de 2012 a 2016.

Quadro 2.1 - Incentivos para geração de energia fotovoltaica no Brasil.

Ano	Regulamentação	Objetivo
2012	Resolução Normativa 482	Estabelecimento de condições gerais para o acesso de microgeração e minigeração distribuída aos sistemas de distribuição de energia elétrica. Criação do Sistema de Compensação de Energia Elétrica. A iniciativa foi desenvolvida pela Agência Nacional de Energia Elétrica (ANEEL).
2013	Portarias 226 e 300	Inclusão da fonte solar (fotovoltaica e heliotérmica) pelo Ministério de Minas e Energia nos leilões de energia A-3/2013 e A-5/2013, respectivamente. Estas portarias abriram a possibilidade de competir igualmente com outras fontes, como a eólica e as térmicas, na modalidade “por disponibilidade”.
2014	Portaria 236	Definição das condições do Leilão de Energia de Reserva de 2014, onde os projetos fotovoltaicos não competiram com outras fontes, apenas entre si.
2014	Lei 19.618	Isenção do Imposto sobre Importação para equipamentos e componentes para a geração de energia solar.
2015	Resolução Normativa 687	Atualização da REN nº 482/2012, diz respeito à possibilidade de instalação de geração distribuída em condomínios, u seja, empreendimentos de múltiplas unidades consumidoras.
2015	Lei 696	Determinar o uso obrigatório de recursos de pesquisa e desenvolvimento em fontes alternativas, por empresas do setor elétrico e pela Indústria do Petróleo. Este projeto de lei visa alterar a Lei nº 9.991 de 24 de julho de 2000, bem como as Leis nº 9.478 de 6 de agosto de 1997 e nº 12.351 de 22 de dezembro de 2010.
2015	Projeto de Lei 1868	Expandir para as famílias do programa “Minha Casa Minha Vida”, a instalação e geração de energia elétrica vinda da energia solar e fomentar, assim, a implantação dos sistemas de energia solar nas novas edificações comerciais e residenciais.
2015	Projeto de Lei 371	Permitir o uso de recursos do Fundo de Garantia do Tempo de Serviço (FGTS) na aquisição e na instalação de equipamentos destinados à geração própria de energia elétrica em residências.
2016	Lei 4.332	Prover uma fonte de recursos para a instalação de unidades de microgeração ou minigeração distribuída de energia elétrica com a criação do Programa Brasil Solar.

Fonte: GOBBO (2018).

Em outros países como China, Estados Unidos da América (EUA), Japão e Alemanha há um incentivo maior em relação à fonte de energia solar. No Quadro 2.2 pode-se observar os modelos de incentivo de cada país mencionado.

Quadro 2.2 - Incentivos para geração de energia fotovoltaica no mundo.

Países	Modelos	Descrição
China	<ul style="list-style-type: none"> • Tarifas fixas; • Subsídios; • <i>Golden Sun</i>; • Redução de impostos; • Empréstimos a juros reduzidos. 	Oferecem garantia de retorno para os proprietários dos sistemas fotovoltaicos sobre a energia gerada, concedidos em contratos de longo prazo, em um período de 15 a 20 anos.
EUA	<ul style="list-style-type: none"> • Redução dos impostos; • Sistemas diferentes para cada estado; • <i>Leasing</i> de placas solares; • Financiamentos e investimentos comunitários; • Créditos de energias renováveis. • Tarifa fixa. 	Os tipos e alcance dos incentivos financeiros e regulatórios variam entre os diversos estados norte-americanos, devido às metas locais de redução de emissões, competitividade de energia fotovoltaica distribuída com a tarifa local e disponibilidade de diferentes fontes de geração.
Japão	<ul style="list-style-type: none"> • Novo Programa Luz do Sol (PD&I); • Lei de Energia Alternativa; • Programas para redução dos Gases de Efeito Estufa (GEE); • Subsídios; • Empréstimos com juros baixos; • Tarifa fixa. 	O governo japonês lançou o programa FiT, que determina que os serviços públicos locais sejam obrigados a comprar 100% da energia gerada a partir de instalações solares de mais de 10 quilowatts (KW) por um período de 20 anos.
Alemanha	<ul style="list-style-type: none"> • Tarifa fixa; • Leilões de Energia Solar. 	Definida pelo <i>German Renewable Energy Act</i> de 2004 que garantia 10 anos de tarifa fixa.

Fonte: GOBBO (2018).

Apesar das várias iniciativas para aumentar a participação da matriz solar no cenário brasileiro, ainda há uma taxa muito baixa de incorporação da matriz (apesar de estar aumentando), sendo de apenas 0,1% do total de energia gerada no país.

2.1.2 Geração de Energia Hidráulica


Desde 1880 a geração de energia elétrica por meio da hidráulica/hídrica é a que mais gera energia no mundo entre as renováveis (CHEN e ENGEDA, 2021). No Brasil as últimas décadas (2000-2018) a geração de energia elétrica tem como principal fonte a hidrelétrica, principalmente por dois grandes fatores, a competitividade econômica e a riqueza de recursos naturais que o território brasileiro detém, isso ocorreu devido em 1970 o país ter passado por

uma crise de petróleo e a partir de então foram realizadas iniciativas do governo para mudar a matriz energética do Brasil, se tornando atualmente um país referência no quesito geração de energia renovável (EPE, 2019).

O Brasil entrou no século XXI com uma problemática em relação a usinas hidrelétricas, como foi citado anteriormente, devido a esta problemática que pode ocorrer com os períodos de baixa pluviosidade dos rios, a fonte de eletricidade por meio da hidrelétrica tende a diminuir conforme outras fontes renováveis se estabelecem no mercado brasileiro, como a eólica e a fotovoltaica, a eólica com melhoria na previsão de geração e a fotovoltaica no acréscimo de iniciativas para diminuir os preços, além do avanço em tecnologias para ambas fontes (DE ABREU MACHADO, 2020).

Observando o Gráfico 2.4 nota-se que há uma instabilidade na geração de energia elétrica por meio da fonte hidráulica/hídrica do Brasil, em que em 2009 foi de 390.988 GWh aumentando e diminuindo ao longo dos anos até o ano de 2018 em que o valor gerado é muito próximo do valor gerado de 2009, com um valor de 388.971 GWh.

Gráfico 2.4 - Fluxo de geração de energia hidráulica no cenário brasileiro (2009-2018).



Fonte: Adaptado de EMPRESA DE PESQUISA ENERGÉTICA – EPE (2019).

2.1.3 Geração de Energia Eólica

Segundo Silva (2003), um dos benefícios mais importantes da energia eólica é a diminuição do dióxido de carbono (CO₂) liberado na atmosfera. Logo essa fonte tem relevância no aspecto ambiental e atrelado ao crescimento dessa fonte na matriz energética houve o

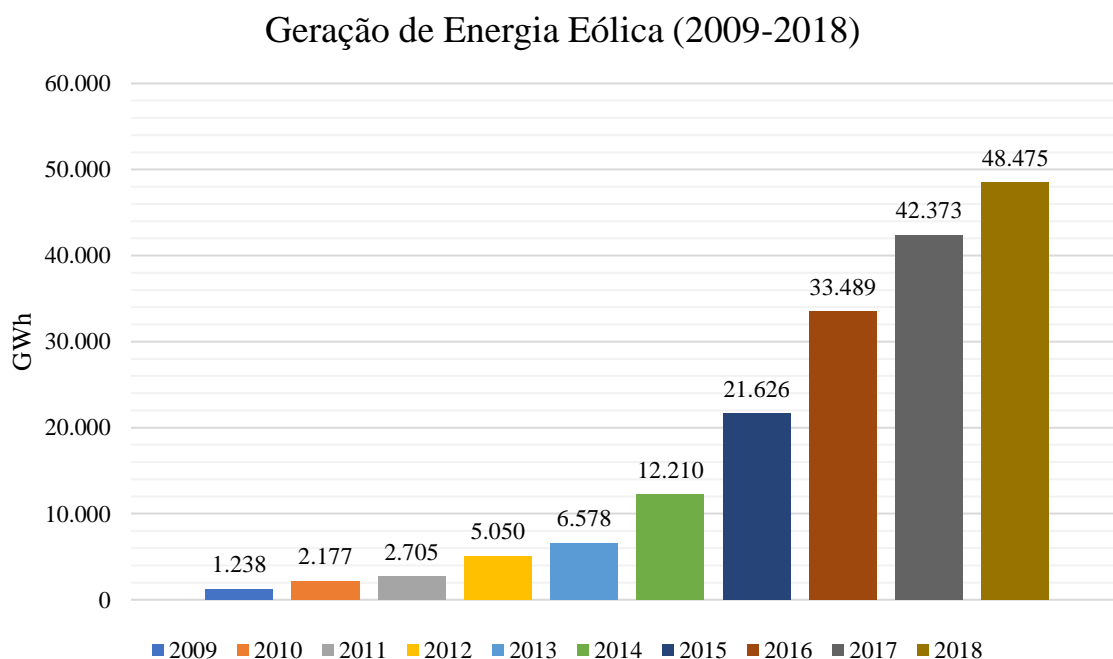
aumento de trabalhos relacionados à previsão da velocidade do vento e da geração de energia elétrica nos últimos anos.

Para a geração de energia eólica é necessário que haja vento, e uma das características do vento é a intermitência (SINGH *et al.*, 2019), que prejudica a geração de energia eólica, para minimização desta problemática é realizado a previsão da velocidade do vento, a fim de diminuir a incerteza da geração de eletricidade (EISSA *et al.*, 2017).

Para a previsão de energia eólica se tem alguns horizontes de tempo a serem previstos, cada um com uma finalidade específica, os mais utilizados são previsões de curto prazo e longo prazo. A previsão de curto prazo se estende em um intervalo de 30 minutos a 6 horas, esse tipo de previsão serve principalmente para realizar despacho das unidades geradoras, venda de energia, atendimento da carga e dentre outras finalidades (BARBOSA DE ALENCAR *et al.*, 2017), enquanto que a de longo prazo está associado a períodos maiores de 1 semana a 1 ano, no qual tem finalidades como a manutenção das redes elétricas e até mesmo dos parques eólicos, além do planejamento de construção de parques eólicos (LEI *et al.*, 2009).

No Gráfico 2.5 é exibido o histórico por ano de 2009 a 2018 da geração de energia eólica no Brasil, medida em GWh. Com este gráfico é possível observar que a geração de energia eólica no Brasil vem crescendo gradativamente no decorrer dos anos (EMPRESA DE PESQUISA ENERGÉTICA - EPE, 2019).

Gráfico 2.5 - Fluxo de geração de energia eólica no Brasil (2009-2018).



*Para estimar dados não informados, foi considerado o fator de capacidade médio do parque eólico nacional de 32,0%.

Fonte: Adaptado de EMPRESA DE PESQUISA ENERGÉTICA - EPE (2019).

Uma das características que impactam no crescimento desta fonte de energia é relação a quantidade de território necessário para a implantação de parques eólicos se comparado a outras fontes como a hidrelétrica e fotovoltaica, no qual para a geração de energia eólica se necessita de menos espaço (PALMER WILSON *et al.*, 2019; MILLER e KEITH, 2018; LUDERER *et al.*, 2019). Pode-se considerar a energia eólica a longo prazo como uma alternativa ímpar entre as energias renováveis, devido a seu caráter inesgotável e por não gerar gases do efeito estufa (DE ABREU MACHADO, 2020).

Porém a geração de energia eólica não tem somente vantagens, existem as desvantagens, que podem ser elencadas como o impacto visual causado pelos parques eólicos, ruídos acústicos causados pelos aerogeradores e turbinas eólicas e o principal impacto causado é a mortalidade da fauna (aves), efeito resultante da implantação de parques eólicos sem planejamento que leve em consideração a rota de migração das aves (PASTOR e DE ALMEIDA MACÊDO, 2020).

Apesar da fonte de eletricidade a partir da hidrelétrica ter suas oscilações, conforme visto no Gráfico 2.4, é possível notar que irá demorar um longo período para que outra fonte renovável supere em termos de geração de energia, já que a mais próxima de superar esta matriz energética é a fonte eólica, que mesmo com a crescente evolução nos últimos anos ainda apresenta dificuldades de crescimento em relação ao potencial que o país possui.

2.2 SÉRIES TEMPORAIS

Uma série temporal nada mais é que um conjunto de dados sequenciais ao longo do tempo (EHLERS, 2007). Exemplos de séries temporais são: Valores diários da poluição em determinada cidade; Valores mensais da temperatura; Valores diários da velocidade do vento; Valores de precipitação atmosférica anual, dentre outros (MORETTIN e TOLOI, 2018; EHLERS, 2007).

Há dois tipos de séries temporais, a primeira e mais utilizada é paramétrico e o segundo não paramétrico, sendo o primeiro caracterizado por ter um número de parâmetros bem definidos, enquanto segundo não há uma definição clara de quantos e quais parâmetros serão utilizados no modelo (MORETTIN e TOLOI, 2018).

As séries temporais possuem algumas características como a sazonalidade, que difere qual modelo será aplicado para a previsão do evento. Alguns exemplos que envolvem a sazonalidade podem ser citados, como: A questão do tráfego de ônibus, que varia durante o dia; as variações climáticas que dependem das estações do ano. Alguns eventos não possuem

sazonalidade, como é o caso do mercado financeiro, outros eventos já possuem uma alta variabilidade como é o caso da velocidade do vento, há também os que possuem uma taxa de variabilidade muito pequena ao longo do tempo, que é o caso da temperatura global (BABU e REDDY, 2014).

Além da sazonalidade, outra característica que uma série temporal pode ter é a tendência, que conforme Ehlers (2007), pode ser de três tipos:

Crescimento linear: Quando o aumento é dado a cada uma unidade ou um valor fixo.

Crescimento exponencial: Ocorre quando o crescimento a um determinado instante t é dado por um fator de $1.x$, onde x é valor de crescimento.

Crescimento amortecido: É o fator de crescimento baseado no aumento por porcentagem em relação a um valor no instante t no passado.

2.3 MODELOS DE PREVISÃO

Alguns modelos foram desenvolvidos ao longo dos anos na tentativa de cada vez mais melhorar a previsão da velocidade do vento, entre os modelos mais conhecidos na literatura pode-se citar: Redes Neurais Artificiais (AHMED e KHALID, 2017; DUAN *et al.*, 2021), Média Móvel Integrada AutoRegressiva (ARIMA) (SINGH *et al.*, 2019; SINGH, SINGH e NEGI, 2019), Média Móvel AutoRegressiva Integrada Exógena (ARIMAX) (XU *et al.*, 2019), Holt-Winters (HW) (KALEKAR *et al.*, 2004), Método Sazonal AutoRegressivo Integrado Média Móvel (SARIMA) (PONGDATU e PUTRA, 2018; ALENCAR *et al.*, 2018). Além de modelos renomados existe um crescente número de trabalhos sendo publicados com modelos híbridos (ALTAN, KARASU e ZIO, 2021; ZHANG, WEI e TAN, 2020; LIU *et al.*, 2020; CHEN *et al.*, 2021; MALIK e YADAV, 2021), aumentando a performance se comparados com modelos simples que usam apenas uma técnica.

Entre os algoritmos simples, os mais populares são ARIMA, SARIMA, RNA e HW.

2.3.1 ARIMA

O modelo ARIMA é um método estatístico para previsão de séries temporais sem sazonalidade (WANG *et al.*, 2015). A principal função deste modelo matemático é prever uma série temporal sem sazonalidade, series essas que não possuem um padrão bem definido ao longo do tempo, o que torna a previsão um pouco mais difícil de ser alcançada, porém há uma

certa regra de mudança no decorrer de uma série temporal sem sazonalidade e o modelo ARIMA é aplicado para descrever esta regra e alcançar uma acuracidade o mais próximo de 100% possível (DUAN *et al.*, 2021).

O modelo matemático ARIMA pode ser definido pela Eq. 2.1 segundo DUAN *et al.*, (2021):

$$y_t = \sum_{i=1}^p \beta_i y_{t-i} + \sum_{j=1}^q \alpha_j e_{t-j} + e_t \quad (2.1)$$

Onde:

p : Ordem da parte autoregressiva;

β_i : Parâmetro autoregressivo;

q : Ordem da parte de média móvel;

α_j : Parâmetro da Média móvel;

t : Termo de erro no momento t .

O ARIMA pode ser explicado em partes, pois o modelo é resultante de uma combinação de estruturas, denominados de “filtros”, tais filtros são conhecidos como Auto Regressivo (AR), Integrado (I) e Média Móvel (MA) (ALENCAR *et al.*, 2018; FANIBAND e SHAAHID, 2021).

AR: Há nesses tipos de modelos uma perspectiva de dependência que pode ser observada em valores anteriores gerados pela média móvel ponderada;

I: É a subtração dos resultados entre o passado e o presente;

MA: É a ocorrência de averiguar por meio de cálculos matemáticos a confiabilidade dos modelos avaliando os erros.

O ARIMA é muito utilizado para previsões da velocidade do vento, como pode ser visto nos trabalhos relacionados no Quadro 2.3.

Quadro 2.3 - Trabalhos relacionados à previsão da velocidade do vento com ARIMA.

Autores	Títulos
(YATIYANA, RAJAKARUNA e GHOSH, 2017)	<i>Wind speed and direction forecasting for wind power generation using ARIMA model</i>
(BANTUPALLI e MATAM, 2017)	<i>Wind Speed forecasting using empirical mode decomposition with ANN and ARIMA models</i>
(SANDHU <i>et al.</i> , 2019)	<i>A Comparative Study of ARIMA and ANN for Short Term Wind Speed Forecasting</i>
(HUSSIN <i>et al.</i> , 2021)	<i>Forecasting Wind Speed in Peninsular Malaysia: An Application of ARIMA and ARIMA-GARCH Models</i>
(FANIBAND e SHAAHID, 2021)	<i>Univariate Time Series Prediction of Wind speed with a case study of Yanbu, Saudi Arabia</i>

Fonte: AUTOR (2021).

Como pode ser visualizado no Quadro 2.3, os trabalhos publicados utilizando ARIMA são atuais e tendem a ser uma consequência natural de utilizar o modelo ARIMA para a criação de novos modelos, os chamados modelos híbridos.

2.3.2 SARIMA

O modelo SARIMA foi proposto em 1976 por Box e Jenkins no trabalho intitulado “*Time series analysis: Forecasting and control San Francisco*” (BOX e JENKINS, 1976). Apesar de ser um modelo bem difundido na literatura, ainda há publicações sendo feitas para a previsão de séries temporais com essa técnica, isso pode ser visto no Quadro 2.4, no qual é exposto alguns trabalhos relacionados a previsão de séries temporais com SARIMA.

Quadro 2.4 - Trabalhos relacionados à previsão de séries temporais com SARIMA.

Autores	Títulos
(RAY <i>et al.</i> , 2021)	<i>Time series SARIMA Modelling and forecasting of monthly rainfall and temperature in the south Asian countries</i>
(QIU <i>et al.</i> , 2021)	<i>Forecasting the incidence of mumps in Chongqing based on a SARIMA model</i>
(KOYUNCU <i>et al.</i> , 2021)	<i>Forecasting COVID-19 impact on RWI/ISL container throughput index by using SARIMA models</i>
(KUMAR <i>et al.</i> , 2021)	<i>Analysis and Prediction of Air Pollution in Assam Using ARIMA/SARIMA and Machine Learning</i>
(XU <i>et al.</i> , 2021)	<i>Prediction of fish migration caused by ocean warming based on SARIMA model</i>
(NOKERI, 2021)	<i>Forecasting Using ARIMA, SARIMA, and the Additive Model</i>

Fonte: AUTOR (2021).

No modelo ARIMA a série temporal tem características lineares tendo como base valores anteriores, já no modelo SARIMA há um incremento muito importante que é a

sazonalidade, utilizando erros que às vezes podem estar defasados e que são múltiplos do intervalo de sazonalidade (BLÁZQUEZ-GARCÍA, *et al.*, 2020).

O modelo SARIMA pode ser definido pela Eq. 2.2 que é a junção das Eq. 2.3 a 2.9.

$$\phi_p(B)\psi_p\tilde{Y}_t = \theta_q(B)Y_Q(B^s)Z_t \quad (2.2)$$

Em que:

$$\tilde{Y}_t = Y_t - E(Y_t), \quad (2.3)$$

$$Y_t = (1 - B)^d(1 - B^s)^D X_t, \quad (2.4)$$

$$\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p, \quad (2.5)$$

$$\psi_p(B^s) = 1 - \psi_1 B^s - \dots - \psi_p B^{sP}, \quad (2.6)$$

$$\theta_q(B) = 1 + \theta_1 B + \dots + \theta_q B^q, \quad (2.7)$$

$$Y_Q(B^s) = 1 + v_1 B^s + \dots + v_Q B^{sQ}, \quad (2.8)$$

$$\{Z_t\} \sim WN(0, \delta^2) \quad (2.9)$$

Onde:

p : Ordem autoregressiva;

q : Média móvel;

d : Ordem das diferenças;

P : ordem autoregressiva sazonal;

Q : Ordem média móvel sazonal;

D : Termo integrado sazonal;

s : Período sazonal (número de ciclos necessários até o padrão de sazonalidade se repetir).

O modelo SARIMA pode ser descrito em cinco etapas:

Tratamento dos dados: Nesta etapa é feito um tratamento nos dados, a fim de deixar a serie temporal estacionária (serie sem variância ao longo do tempo), isso é feito por meio dos

valores a serem definidos no intervalo de diferenças sazonais (D) e as não sazonais (d) (HYNDMAN e ATHANASOPOULOS, 2018).

Identificação e estimação: Etapa responsável por identificar e estimar os parâmetros do modelo SARIMA, como os valores de (p,q,P,Q) (ALENCAR *et al.*, 2018). Isso é feito por meio da análise da AutoCorrelação de Funções do inglês *AutoCorrelation Functions* (ACF) e a AutoCorrelação Parcial Gráficos de Funções do inglês *Partial AutoCorrelation Function* (PACF) (BLÁZQUEZ-GARCÍA, *et al.*, 2020).

Seleção do modelo: Etapa em que é definido os erros a serem utilizados para testar o modelo SARIMA, em que o que apresentar o menor erro é o modelo a ser utilizado. Para os erros é utilizado normalmente a Raiz quadrada do Erro Quadrático Médio do inglês *Root Mean Squared Error* (RMSE) (BLÁZQUEZ-GARCÍA, *et al.*, 2020).

Diagnóstico: Nesta etapa é feito o diagnóstico do modelo para que seja identificado os chamados ruídos brancos, que devem ser de valor zero, indicando que não há variância na série temporal (HYNDMAN e ATHANASOPOULOS, 2018).

Previsão: Etapa em que indica que o modelo ideal foi alcançado e é aplicado para previsão de uma série temporal, como é o caso da velocidade do vento (ALENCAR *et al.*, 2018).

2.3.3 Modelo Holt-Winters

A suavização exponencial de Holt-Winters também conhecido como Suavização Exponencial Tripla é um método classificado como estatístico, que tem por finalidade ajustar as mudanças estocásticas que ocorrem nos dados que se pretende prever. Tal modelo é bastante empregado na previsão, pois possui algumas características interessantes, como a boa acurácia, capacidade de se auto ajustar e simplicidade de implementação (GARDNER, 2006). O modelo de Holt-Winters é utilizado quando os dados têm uma sazonalidade e tendência (PONGDATU e PUTRA, 2018).

No trabalho realizado por Barros, Oliveira e Souza (2015), é mostrado o desenvolvimento de uma nova metodologia para prever a geração de energia por meio do vento, no qual foi utilizado uma variante do modelo de Holt-Winters.

A Suavização Exponencial Tripla possui três elementos para suavização, sendo eles Nível (Et), Tendência (Tt) e o Componente Sazonal (St), cada um caracterizado pelos seguintes

coeficientes (α, β, γ) (NAVARRO e NAVARRO, 2019). Para o modelo de Holt-Winters se adota duas vertentes a depender do efeito de sazonalidade, podendo ser um modelo aditivo ou multiplicativo (ASHOOR e KAZEM, 2021; NURHAMIDAH, NUSYIRWAN e FAISOL, 2020).

O modelo aditivo pode ser definido pela junção das Eq. 2.10 a 2.13.

$$E_t = \alpha(Y_t - S_{t-p}) + (1 - \alpha)(E_{t-1} + T_{t-1}) \quad (2.10)$$

$$T_t = \beta(E_t - E_{t-1}) + (1 - \beta)T_{t-1} \quad (2.11)$$

$$S_t = \gamma(Y_t - E_t) + (1 - \gamma)S_{t-p} \quad (2.12)$$

$$\hat{Y}_{t+n} = E_t + nT_t + S_{t+n-p} \quad (2.13)$$

O modelo multiplicativo pode ser definido pela junção das Eq. 2.14 a 2.17.

$$E_t = \alpha \frac{Y_t}{S_{t-p}} + (1 - \alpha)(E_{t-1} + T_{t-1}) \quad (2.14)$$

$$T_t = \beta(E_t - E_{t-1}) + (1 - \beta)T_{t-1} \quad (2.15)$$

$$S_t = \gamma \frac{Y_t}{E_t} + (1 - \gamma)S_{t-p} \quad (2.16)$$

$$\hat{Y}_{t+n} = (E_t + nT_t)S_{t+n-p} \quad (2.17)$$

Onde:

\hat{Y}_{t+n} = Carga prevista para o tempo $(t+n)$

Y_t = Dados atuais

E_t = Nível básico da série temporal

T_t = Valor de tendência esperado

S_t = Fator sazonal

$n = 1, 2, \dots, p$

p = Período


α, β, γ = Coeficientes de suavização (de 0 a 1)

Os modelos do tipo aditivo são utilizados quando a base de dados utilizada não possui tendência e/ou quando a sazonalidade depende da extensão da base de dados (NURHAMIDAH, NUSYIRWAN e FAISOL, 2020). Já o modelo multiplicativo é usado quando a sazonalidade tem uma variação em sua amplitude (altura) e cresce ao longo do tempo (VENTURA *et al.*, 2019; WINTERS, 1960).

2.3.4 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) foram constituídas pela primeira vez em 1943 (MCCULLOCH e PITTS, 1943), são baseadas nos neurônios dos seres humanos e tentam imitar o comportamento do cérebro para prever acontecimentos futuros baseados em uma experiência ou amostra de dados. De acordo Barros *et al.*, (2018), a representação de um neurônio artificial é idêntica a um neurônio biológico, tendo algumas características em comum, tal comparação entre os neurônios pode ser visualizada na Figura 2.1.

Figura 2.1 - Comparação entre neurônios biológicos e artificiais.



Fonte: Adaptado de Barros *et al.* (2018).

No processo de uma RNA simples como é mostrado na Figura 2.1, a rede que é composta por n neurônios artificiais que têm a capacidade de efetuar diversos cálculos matemáticos de uma complexidade elevada, assim como os neurônios biológicos dos seres humanos (GÉRON, 2019). Com isso as RNAs vêm sendo comumente utilizadas como forma de previsão de séries temporais, principalmente na previsão da velocidade do vento e geração de energia eólica (DOS SANTOS e SPANCERSKI, 2021).

Existem algumas variantes de RNA e uma delas é usada no modelo híbrido proposto neste trabalho, que é o modelo recorrente de Rede Neural conhecido como Não Linear AutoRegressiva com Entradas Exógenas (NARX), utilizado para séries temporais (MATKOVSKYY e BOURAOUI, 2019; WUNSCH, LIESCH e BRODA, 2018;

CARPINTEIRO *et al.*, 2006). Esta variação de RNA recebe dados de entrada exteriores como também dados resultantes de saída da própria rede, logo o resultado final é em função do tempo (WILMS *et al.*, 2019; SOUZA *et al.*, 2019; GÉRON, 2019). A Eq. 2.18 representa o modelo de rede citado.

$$\hat{y}(k) = F(u(k-1), \dots, u(k-n), y(k-1), \dots, y(k-m)) \quad (2.18)$$

Onde:


u = Entrada externa na rede;

y = Resposta anterior da rede;

\hat{y} = Saída estimada da rede.

Na Figura 2.2 é apresentada de forma detalhada a arquitetura da Rede Neural Não Linear AutoRegressiva com Entradas Exógenas (NARX).

Figura 2.2 - Arquitetura NARX.




Fonte: AGUILAR-LOBO *et al.* (2015).

Uma Rede Neural Recorrente como é o NARX, tem uma saída no instante t que depende de todos os valores de entrada anteriores, funcionando assim como uma memória, preservando uma “memória”, tal como ocorre nos neurônios biológicos, devido a esta característica da rede

recorrente, este efeito é conhecido como Células de Memória (CM) (GÉRON, 2019). As CMs podem ser melhores exemplificadas por meio da Figura 2.3.

Figura 2.3 - Células de Memória.



Fonte: DOS SANTOS e DA SILVA OLIVEIRA (2020).

Na Figura 2.3 é mostrado a Célula de Memória Longa de Curto Prazo do inglês (*Long short-term memory*, LSTM) que foi concebido em 1997 pelos pesquisadores Hochreiter e Schmidhuber, que tem a finalidade de aumentar o desempenho ao longo do tempo com um menor tempo de convergência, fazendo com que a rede consiga guardar os dados necessários para aprendizagem e eliminar os desnecessários (HOCHREITER e SCHMIDHUBER, 1997).

2.3.5 Algoritmos de Treinamento

2.3.5.1 Levenberg-Marquardt

O algoritmo Levenberg-Marquardt foi constituído em duas etapas, o primeiro em 1944 por Levenberg e foi complementado e finalizado por Marquardt em 1963, daí surge o nome do algoritmo (LM-Levenberg-Marquardt) (HENNINGSEN, HENNINGSEN e VAN DER WERF, 2019). Levenberg-Marquardt é muito utilizado como algoritmo de treinamento nas Redes Neurais Artificiais, pois é considerado por muitos autores o algoritmo mais rápido, porém é válido ressaltar que o mesmo necessita de mais poder computacional para realizar a otimização do que a maioria dos outros algoritmos (GONÇALVES *et al.*, 2010).

Este algoritmo tem sua principal aplicação voltada ao problema no ajuste de curva dos mínimos quadrados (DADA *et al.*, 2021), onde o problema pode ser representado pela Eq. 2.19:

$$\hat{\beta} \in \operatorname{argmin}_{\beta} S(\beta) \equiv \operatorname{argmin}_{\beta} \sum_{i=1}^m [y_i - f(x_i, \beta)]^2 \quad (2.19)$$

Onde:

$\beta = \text{Parâmetros};$

$m = \text{Pares Empíricos};$

$x_i = \text{Variáveis Independentes};$

$y_i = \text{Variáveis Dependentes};$

$f(x_i, \beta) = \text{Modelo};$

$S(\beta) = \text{Desvios};$

2.3.5.2 Bayesian Regularization

O algoritmo de treinamento BS-Bayesian Regularization é um modelo que transforma uma regressão não linear a um modelo estatístico, tendo como benefício o não uso da validação e sua robustez. Assim, RNAs e suas variações que utilizam o Bayesian Regularization tem uma robustez maior que as que utilizam o algoritmo de treinamento backpropagation, justamente por não ser uma necessidade fazer a etapa de validação (BARROS *et al.*, 2018).

A equação que define as redes Bayesian Regularization é dada pela Eq. 2.20.

$$F = \beta E_D + \alpha E_W \quad (2.20)$$

2.3.5.3 Scaled Conjugate Gradient

O algoritmo SCG-Scaled Conjugate Gradient é um modelo para aprendizado e é muito utilizado para o treinamento de RNAs, este algoritmo funciona como os princípios básicos de otimização, tendo uma função objetivo e convergindo até o alvo, porém o controle do tamanho de passos que o mesmo dar em direção ao alvo é mais eficiente quando se trata de informações de segunda ordem (BARROS *et al.*, 2018).

A Eq. 2.21 representa o modelo matemático do algoritmo.

$$E_{qw}(y) = E(w) + E'(w)y + \frac{1}{2}y^T E''(w)y \quad (2.21)$$

2.3.6 Funções de Ativação

As funções de ativação são utilizadas para ativar os neurônios das camadas, para cada camada há uma função de ativação, podendo elas se repetirem (KOÇAK e ŞIRAY, 2021). Entre as funções de ativação que podem ser utilizadas na rede neural estão: Sigmoide, Tangente Hiperbólica, Unidade Linear Retificada, no qual podem ter suas expressões observadas na Tabela 2.2.

Tabela 2.2 - Funções de ativação.

Sigla	Função	Expressão
SG	Sigmoide	$S(x) = \frac{1}{1 + e^x}$
TanH	Tangente Hiperbólica	$\tan H(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$
ReLU	Unidade Linear Retificada	$ReLU(x) = \max\{0, x\}$, sendo $\begin{cases} 1, se x \geq 0 \\ 0, c. c \end{cases}$

Fonte: Adaptado de KOÇAK e ŞIRAY (2021); REIS *et al.* (2018).

CAPÍTULO 3

3 MATERIAIS E MÉTODOS

3.1 MATERIAIS

Para o desenvolvimento do modelo híbrido de previsão, foi feito o estudo das principais técnicas de previsão, no qual foram selecionados os modelos de Holt-Winters devido a característica de trabalhar bem com dados com sazonalidade, assim a escolha se justifica para suavizar a aleatoriedade dos dados na série temporal da velocidade do vento e demais variáveis de entrada. A outra técnica escolhida foi o modelo NARX, que é próprio para trabalhar com previsões de séries temporais, que conforme a literatura expõe, a RNA é um dos modelos mais eficientes na previsão da velocidade dos ventos, sendo o NARX uma RNA recorrente.

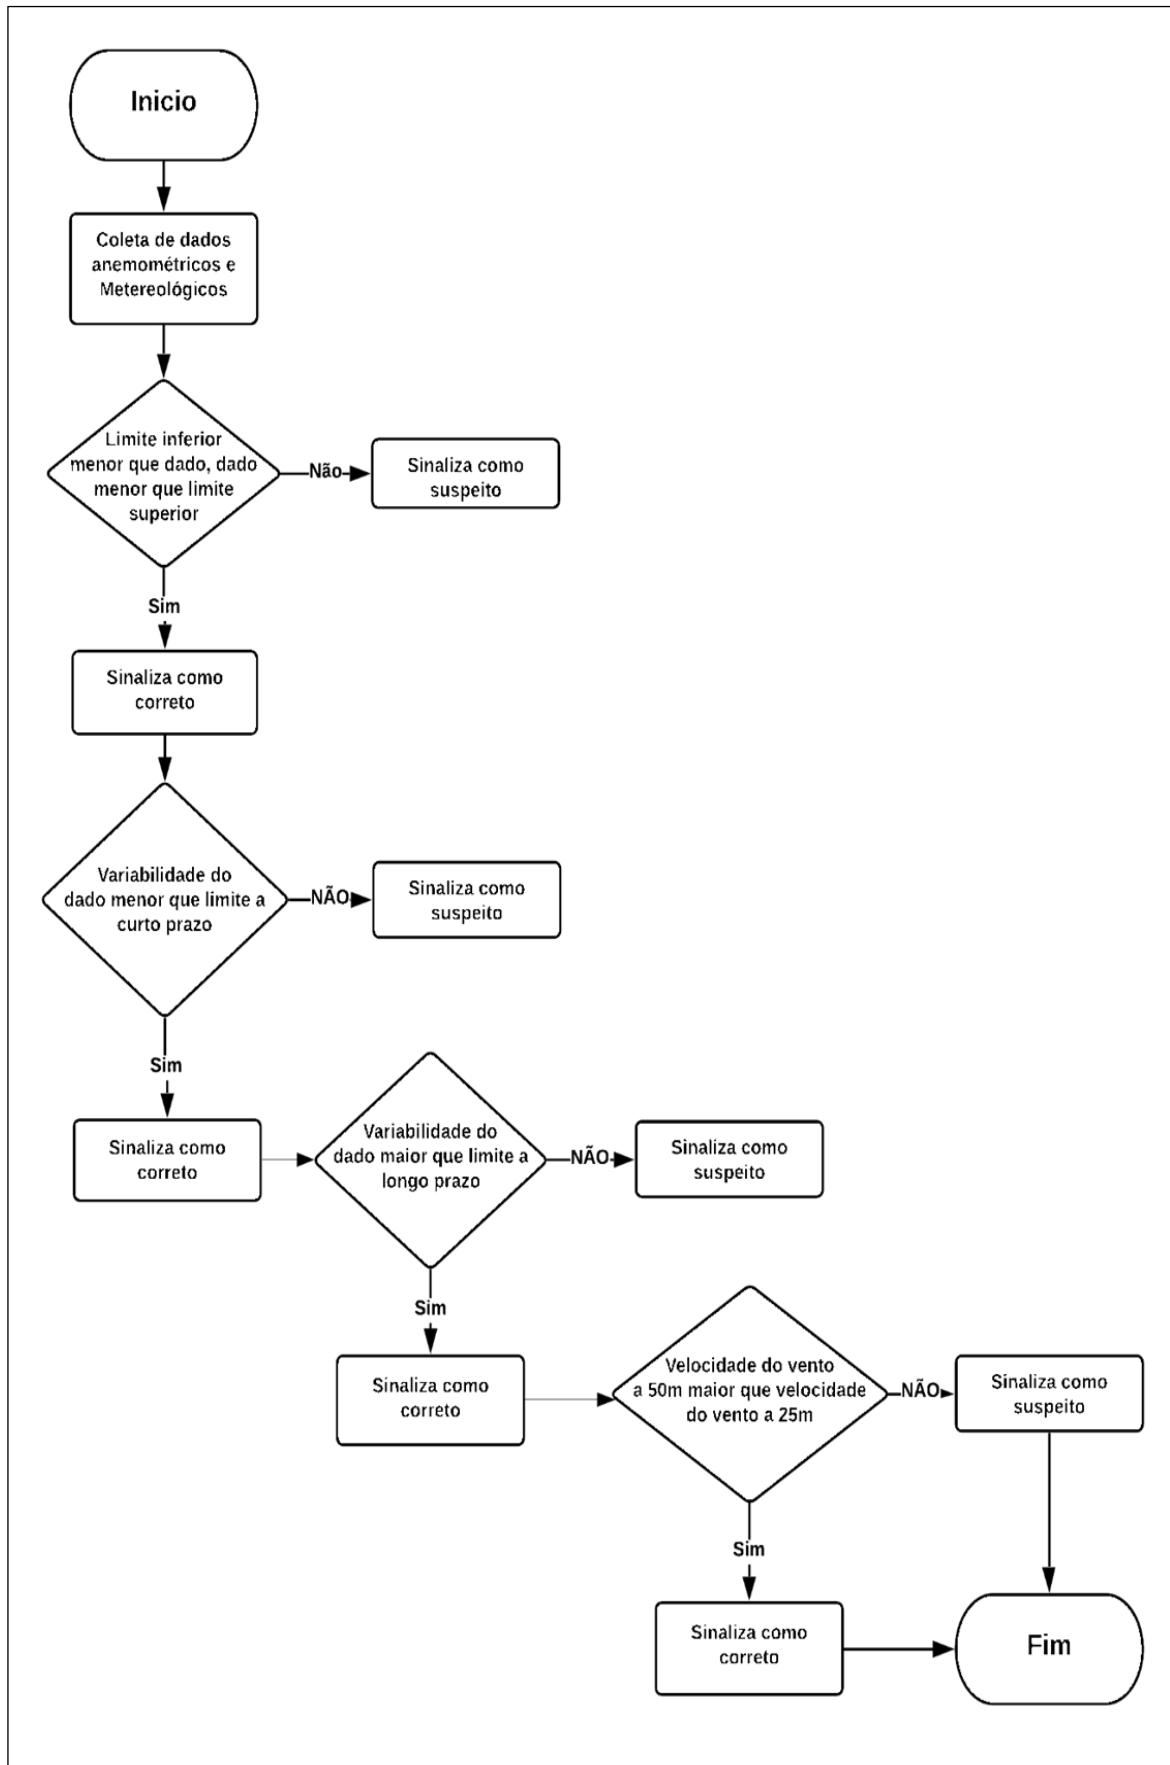
Os testes foram realizados em duas bases de dados, sendo dividido assim em duas etapas, inicialmente na primeira etapa de testes foi utilizado como base os dados do projeto SONDA (Sistema de Organização Nacional de Dados Ambientais) organizado pelo INPE (Instituto Nacional de Pesquisas Espaciais), no qual optou-se por utilizar os dados anemométricos da estação de Brasília – BRB, onde foram usados dados dos anos de 2018 a março de 2019 para treinamento validação e testes da rede neural recorrente NARX, porém foi identificado que os dados não estavam alinhados e ajustados, tendo muitas lacunas, o que pode prejudicar a performance da previsão.

Logo foi utilizado na segunda etapa de testes a base de dados de Petrolina (PTR) (também do projeto SONDA) no período de 2006 á 2015, que foi ajustada e teve as lacunas preenchida por meio de interpolação, trocando valores nulos por uma média da coluna correspondente, à base de dados da estação de PTR teve menos dados nulos e suspeitos que a base de BRB, logo a PTR foi a escolhida para ser aplicado no modelo final proposto.

De acordo com SONDA (2021), é realizado uma avaliação na confiabilidade dos dados coletados, devido alguns fatores como mau funcionamento dos equipamentos, relâmpagos ou até mesmo acidentes com animais, seguindo as estratégias de controle de qualidade de dados utilizada pela Baseline Surface Radiation Network (BSRN) juntamente com critérios estabelecidos pela Webmet (<http://www.webmet.com/>).

Na Figura 3.1 é apresentado o fluxograma adaptado do projeto SONDA para validação dos dados.

Figura 3.1 - Fluxograma de validação de dados SONDA.



Fonte: Adaptado de SONDA (2021).

No fluxograma da Figura 3.1 o processo de validação pelo projeto SONDA é dividido em 5 etapas, uma de coleta e quatro de verificação/validação dos dados:

- 1- Coleta de dados anemométricos e meteorológicos na estação.
- 2- Há uma verificação se o limite inferior é menor que o dado e se o dado é menor que o limite superior, caso não seja, o dado é marcado com uma sinalização por meio de um código numérico que o identifica como um dado suspeito. Caso se o dado passe positivamente pela validação, o dado é marcado com um código que sinaliza que o dado está correto nesta primeira etapa de verificação.
- 3- Na segunda fase de verificação dos dados coletados é verificado se a variabilidade do dado é menor que o limite a curto prazo, caso o dado não passe por esta condição é feito o processo de marcação do dado com um código, sinalizando que o mesmo não passou na validação da segunda etapa de verificação. Caso o dado satisfaça a condição, o dado é marcado com um código sinalizando a aprovação do dado pela validação. Vale ressaltar que os códigos de marcação que validam ou não os dados são diferentes para cada etapa de verificação, sendo possível assim identificar em qual fase o dado não passou pela validação.
- 4- A terceira fase de validação é composta pela verificação da variabilidade do dado maior que o limite a longo prazo, caso o dado não satisfaça tal condição o dado é marcado por um código de reprovação, se o dado satisfizer a condição de verificação para a validação, o dado é marcado com um código de aprovação, levando-o a última fase de validação (Etapa 4 de validação).
- 5- Na quarta e última etapa de validação dos dados, é realizado uma comparação da velocidade do vento captado a 50 metros de altura e a mesma a uma altura de 25 metros, caso a velocidade do vento a 50 metros de altura seja menor que a 25 metros de altura, o dado é marcado com um código de reprovação de validação da quarta etapa de verificação. Caso o dado da velocidade do vento a 50 metros de altura seja maior que 25 metros, o dado é catalogado como verídico. Chegando assim ao fim do processo de validação.

Na etapa de validação é utilizado alguns algoritmos para identificar algumas características importantes das variáveis como pode ser observado no Quadro 3.1.

Quadro 3.1 - Características avaliadas no processo de validação dos dados pela SONDA.

Etapas	Variáveis Anemométricas	Variáveis Meteorológicas
1	Algoritmo 1 Dado suspeito quando fisicamente impossível.	
2	Algoritmo 2 Dado suspeito quando o evento é extremamente raro.	
3	Algoritmo 3 Dado suspeito quando apresenta uma evolução temporal não condizente com o esperado para a variável.	
4	Algoritmo 4 Dado suspeito quando inconsistente com medidas apresentadas por outras variáveis da mesma estação.	Não aplicado

Fonte: SONDA (2021).

Apesar de todo o cuidado que a SONDA tem em validar os dados, ainda se torna necessário verificar e normalizar os dados.

3.1.1 Normalização de Dados

A normalização dos dados é feita pela própria SONDA, porém devido alguns erros nos equipamentos anemométricos a coleta teve alguns dados que não foi possível a captação, logo foi necessário fazer uma nova normalização dos dados, para que houvesse uma maior confiabilidade dos dados reais e não houvesse lacunas entre um dado e outro.

3.1.2 Implementação do Algoritmo Híbrido

Para a implementação do algoritmo foi utilizado o software *MatLab*® em sua versão 2016a, que é um software altamente reconhecido no cenário internacional e foi escolhido por possuir um toolbox do modelo NARX, facilitando a implementação do algoritmo.

Foi utilizado o modelo Holt-Winters para suavizar os dados, gerando as variáveis independentes e dependente de forma mais normalizada, consistente e suavizada. Assim os dados suavizados são introduzidos no Modelo NARX e há a previsão da velocidade do vento.

3.1.3 Erros

O Erro Quadrático Médio (MSE) e a Raiz quadrada do Erro Quadrático Médio (RMSE) podem ser definidos pela Eq. 3.1 e 3.2 respectivamente.

$$MSE = \frac{1}{N} \sum_{k=1}^N (SoC_{th}(k) - SoC(k))^2 \quad (3.1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (SoC_{th}(k) - SoC(k))^2} \quad (3.2)$$

O MSE e o RMSE são indicadores usados para mostrar o quão os números analisados possuem acurácia, e quanto mais próximos do valor de zero melhor é a acurácia, caso se iguale a zero, indica uma acurácia perfeita de 100% (BHARDWAJ *et al.*, 2013). Tanto o MSE quanto o RMSE são positivos sendo o menor valor possível o zero. Outro método estatístico para avaliar a performance da rede é o Erro Médio Percentual Absoluto (MAPE) (KAUSHIKA, TOMAR e KAUSHIK, 2014), que é dado em porcentagem e pode ser definido pela Eq. 3.3, quanto menor o erro, melhor é a performance.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{y - x}{w} \times 100 \quad (3.3)$$

Onde:

x = Dados de entrada;

y = Dados previstos pela rede;

w = Quantidade de elementos do vetor.

3.2 MÉTODOS

3.2.1 Arquitetura Utilizada da RNA (NARX)

Na Figura 3.2 é apresentada a arquitetura da rede NARX utilizada no modelo híbrido, configurada com 4 variáveis de entrada e 1 de saída. Sendo as variáveis utilizadas na entrada:

Pressão Atmosférica;

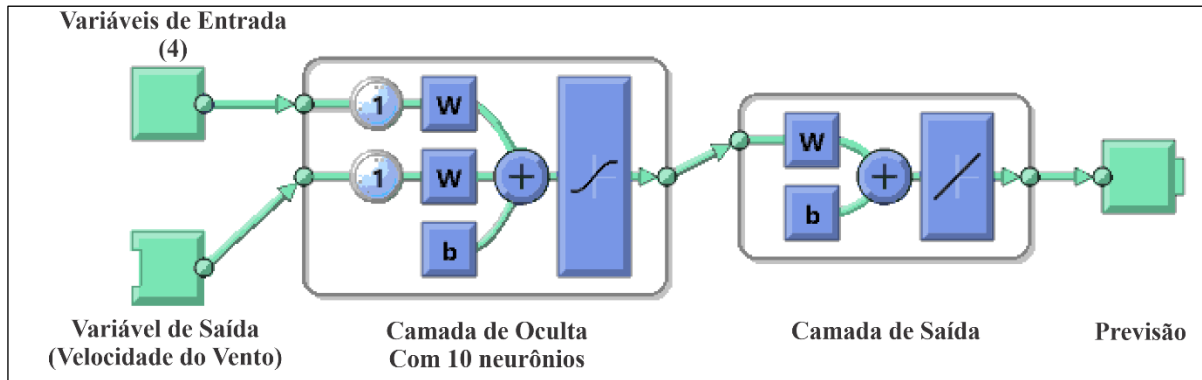
Umidade Relativa do Ar;

Direção do Vento;

Temperatura do Ar.

Já como alvo a ser encontrado foi utilizado a variável Velocidade do vento.

Figura 3.2 - Arquitetura e configurações utilizadas na rede NARX.




Fonte: AUTOR (2021).

A rede foi configurada com 4 entradas e uma saída, tendo uma camada oculta com 10 neurônios. Vale ressaltar que esta estrutura de rede foi aplicada para todos os cenários testados, incluindo o modelo híbrido proposto HW-NARX.

A rede foi treinada com três algoritmos sendo eles, (LM) (BS) e (SCG), e foi feita uma comparação entre os três para se obter o melhor dos algoritmos nos horizontes de tempo testados, isso para a primeira etapa de testes, para a segunda foi utilizado o algoritmo com melhor performance entre os testados.

Para o treinamento foram utilizados 70% dos dados, para validação 15% e para os testes 15%, conforme pode ser observado na Figura 3.3, esta configuração foi utilizada tanto na primeira etapa de testes como na segunda.

Figura 3.3 - Divisão de dados para o modelo NARX.



Fonte: AUTOR (2021).

3.2.2 Primeira Etapa de Testes

Para a realização das simulações foi utilizado o notebook com as configurações descritas no Quadro 3.2.

Quadro 3.2 - Setup de configurações do notebook utilizado para os experimentos.

Elementos	Descrição
Processador	Intel Core i7-8565U com 1.80 GHz
Memória RAM	16 GB com 2400 MHz
Placa de Vídeo	Nvidia GeForce MX130 com 2 GB de RAM GDDR5
SSD	512 GB
Sistema Operacional	Windows 10 Home Single Language

Fonte: AUTOR (2021).

A primeira etapa consiste em realizar testes para encontrar o melhor algoritmo de treinamento para a rede neural NARX. A quantidade de dados utilizados para cada variável dos cenários apresentados está indicada na Tabela 3.1.

Tabela 3.1 - Quantidade de dados utilizados na base BRB.

Horizonte	Quantidade de dados utilizados
10 minutos	18391
1 hora	18391
1 dia	18391

Fonte: AUTOR (2021).

Na Tabela 3.1 a quantidade de dados total utilizada para a etapa 1 de testes foi igual para todos os horizontes, incluindo treinar, validar e testar a rede, vale ressaltar que os 18391 dados estão se referindo a quantidade de dados de cada variável de entrada (Pressão Atmosférica; Umidade Relativa do Ar; Direção do Vento e Temperatura do Ar) e saída (Velocidade do vento). A quantidade de dados utilizada para cada horizonte está em minutos, sendo assim para o horizonte de dia foram utilizados aproximadamente dados de 13 dias.

A Tabela 3.2 exibe uma amostra de dados utilizada, na qual os dados são coletados a cada 1 minuto pelos anemômetros das torres eólicas da estação de BRB.

Tabela 3.2 - Amostra de dados de BRB.

Ano	Dia	Hora	Minuto	Temperatura	Umidade	Pressão	Velocidade do Vento	Direção do Vento
2019	1	1	0	19,84	93,8	897,65	0,231	320,5
2019	1	1	1	19,64	93,9	897,64	0,272	318,2
2019	1	1	2	19,54	93,8	897,64	0,179	317,4
2019	1	1	3	19,67	93,8	897,64	0,171	316,4
2019	1	1	4	19,62	93,8	897,64	0,228	308,1
2019	1	1	5	19,41	93,8	897,72	0,274	303,2
2019	1	1	6	19,35	93,7	897,72	0,314	298,6

Ano	Dia	Hora	Minuto	Temperatura	Umidade	Pressão	Velocidade do Vento	Direção do Vento
2019	1	1	7	19,48	93,8	897,64	3,54	291,2
2019	1	1	8	19,56	93,7	897,72	3,98	280,1
2019	1	1	9	19,39	93,7	897,72	5,62	249,5
2019	1	1	10	19,56	93,7	897,8	5,35	249,9
2019	1	1	11	19,56	93,7	897,8	5,68	249,9
2019	1	1	12	19,53	93,6	897,8	5,85	248,1
2019	1	1	13	19,59	93,6	897,8	5,33	231,6
2019	1	1	14	19,38	93,6	897,88	5,16	232,9

Fonte: SONDA (2021).

Os dados utilizados são categorizados por Ano, Dia, Hora, Minuto, Temperatura, Umidade, Pressão, Velocidade do Vento e Direção do Vento. Algumas características importantes a se levar em consideração são:

Minuto: Os minutos são sequenciais e coletados a cada 1 minuto pelos anemômetros;

Temperatura: A temperatura é dada em graus Celsius a 25 metros de altura;

Umidade Relativa do Ar: É dada em porcentagem (%), sendo uma variável meteorológica;

Direção do Vento: A direção do vento é dada em graus a uma altura de 25 metros de 0° (Norte) a 360° (Sentido horário);

Pressão Atmosférica: É dada em milibares, assim como na umidade relativa do ar, também é uma variável meteorológica;

Velocidade do Vento: É dada em milissegundo (ms) a uma altura de 25 metros.

3.2.3 Segunda Etapa de Testes

Na Tabela 3.3 é mostrado a quantidade de dados utilizados em cada horizonte de tempo, sendo que cada conjunto está tratado e normalizado na unidade de medida equivalente ao horizonte, por exemplo os dados do horizonte de 10 minutos estão em minutos, os dados do horizonte de hora estão horas e assim sucessivamente para os horizontes de dia e semana.

Horizonte	Quantidade de dados utilizados
10 minutos	4300
1 hora	4325
1 dia	3784
1 semana	523

Fonte: AUTOR (2021).

Para a segunda etapa de testes foi acrescentado mais um horizonte de tempo em relação a primeira etapa, que foi o horizonte de semana, a fim de observar o comportamento do modelo para a previsão de médio prazo.

Na Tabela 3.4 é exibido uma amostra dos dados da base PTR, com as colunas Ano, Dia, Hora, Minuto, Temperatura, Umidade, Pressão, Velocidade do Vento e Direção do Vento, vale ressaltar que a amostra de dados na Tabela 3.4 está sem tratamento.

Os dados da Temperatura, Umidade e Pressão não variam tanto, pois os dados estão sendo coletados a cada minuto. No minuto 7 e 8, pode-se observar que os dados têm valores muito próximos, e mesmo assim a velocidade do vento altera, isso se dá pelo fato que existem outras variáveis que impactam na velocidade do vento que não estão sendo incluída no modelo de previsão ou não são captadas pelos anemômetros.

Tabela 3.4 - Amostra de dados de PTR.

Ano	Dia	Hora	Minuto	Temperatura	Umidade	Pressão	Velocidade do Vento	Direção do Vento
2015	1	1	0	27.66	60.77	969.54	3.113	119.6
2015	1	1	1	27.62	60.90	969.53	5.831	109.9
2015	1	1	2	27.64	60.97	969.53	5.621	114.9
2015	1	1	3	27.59	60.90	969.60	4.588	121.4
2015	1	1	4	27.65	60.90	969.53	3.703	120.1
2015	1	1	5	27.64	61.03	969.59	3.882	121.4
2015	1	1	6	27.63	61.16	969.60	3.411	114.4
2015	1	1	7	27.55	61.33	969.53	3.457	117.1
2015	1	1	8	27.55	61.39	969.54	3.635	121.4
2015	1	1	9	27.47	61.56	969.47	5.689	120.7

Fonte: SONDA (2021).

Na Tabela 3.5 são mostrados os mínimos, máximo e médias das variáveis utilizadas para a previsão da velocidade do vento em minutos. Pode-se perceber analisando a Tabela 3.5 que a variável que menos varia é a velocidade do vento e a temperatura, sendo que a direção do vento é a que mais varia tendo alcançado valores de 2,40 a 359,5, tendo em vista que o limite inferior desta variável é 0 e o superior é 360, pode-se afirmar que a mesma variou cerca de 99,19 do limite inferior ao superior.

Tabela 3.5 - Mínimos, máximos e médias da base de dados de PTR.

	Temperatura	Umidade	Pressão	Velocidade do Vento	Direção
Mínimo	20,91	31,00	966,97	4,28	2,40
Máximo	36,11	98,4	975,07	12,99	359,5
Média	27,82330698	64,43542791	970,9331047	8,323967442	144,6213488

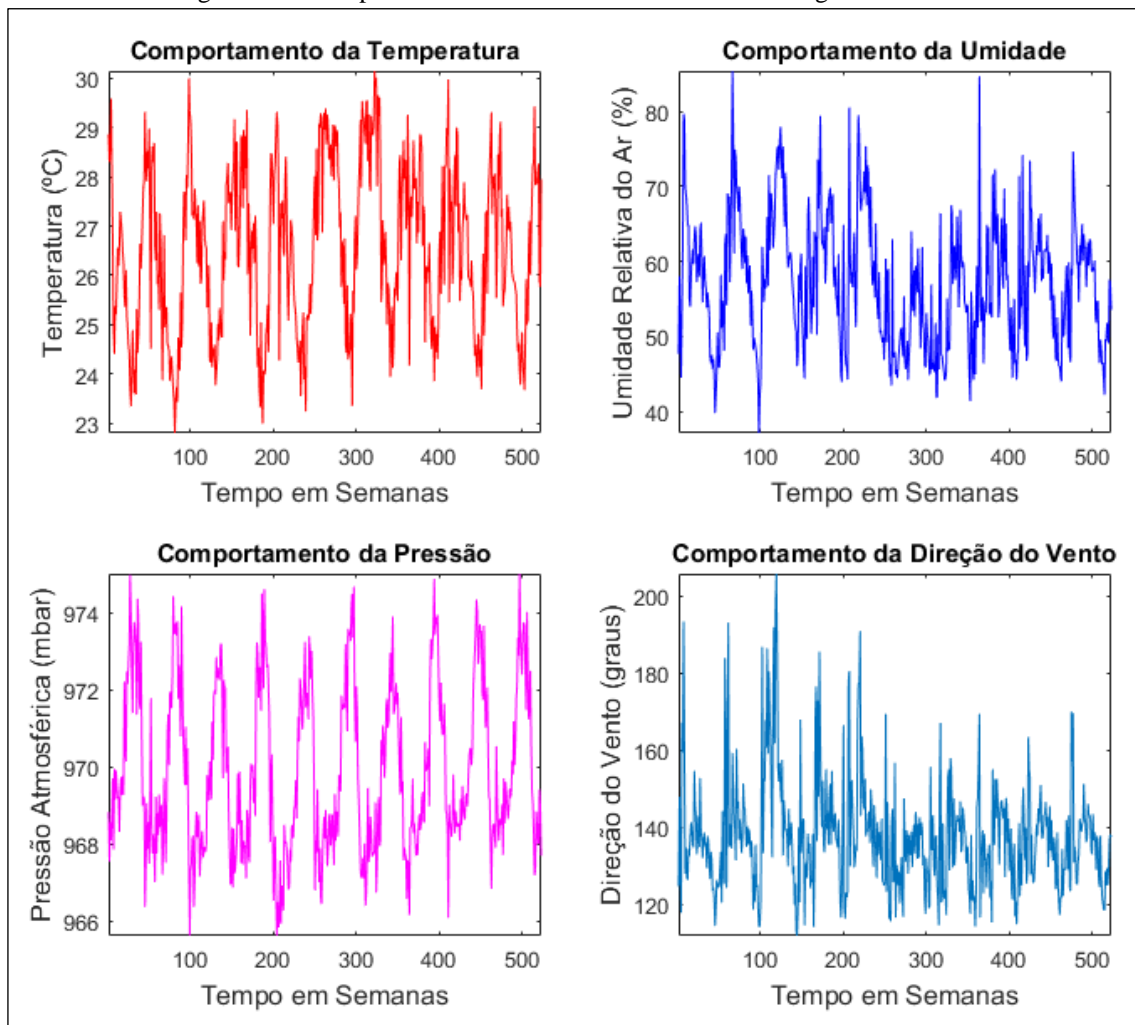
Fonte: AUTOR (2021).

Na Figura 3.4 é mostrado o comportamento das variáveis de entrada utilizadas para os testes do modelo proposto HW+NARX e comparativo com os demais algoritmos (HW e NARX).

Os comportamentos das quatro variáveis possuem um ciclo sazonal perceptível, no qual as unidades de medida das variáveis estão em semanas, diferentemente dos dados apresentados na Tabela 3.5 que estão em minutos. Os dados utilizados nos gráficos contidos na Figura 3.4 são do período de 10 anos, de 2006 a 2015.

Dentre as variáveis de entrada, a que menos varia é a pressão, sendo está a menos impactante na velocidade do vento. Já a temperatura, umidade e direção do vento estão ligadas diretamente na velocidade do vento.

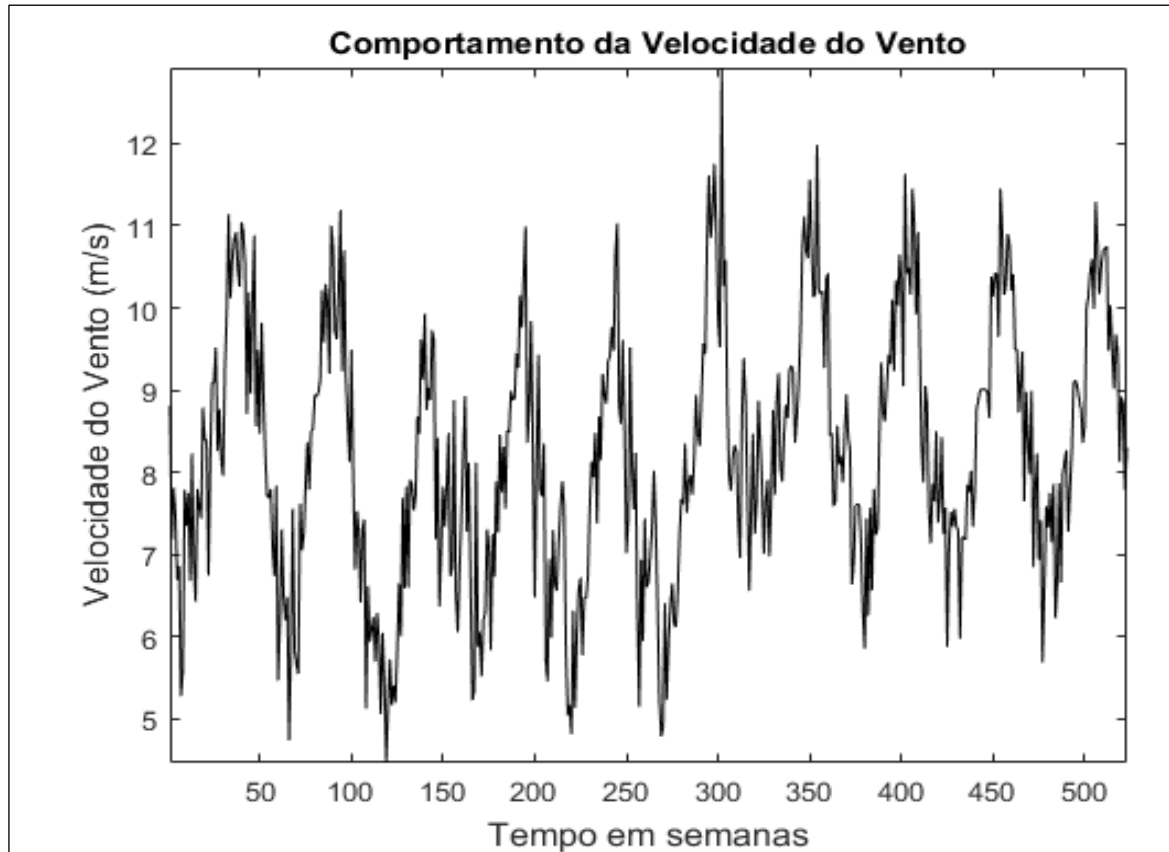
Figura 3.4 - Comportamento das variáveis de entrada ao longo de 10 anos.



Fonte: AUTOR (2021).

Na Figura 3.5 é apresentado o comportamento da velocidade do vento ao longo de 10 anos, sendo o período de 2006 a 2015. A variável velocidade do vento possui seus ciclos de sazonalidade bem definidos em intervalos de 52 semanas, que corresponde a um ano.

Figura 3.5 - Comportamento da Velocidade do Vento ao longo de 10 anos.



Fonte: AUTOR (2021).

Tendo como base as Figuras 3.4 e 3.5, pode-se observar que o comportamento da temperatura, umidade e direção do vento tem uma semelhança com a velocidade do vento, já a variável pressão atmosférica não possui uma influência muito alta na velocidade do vento, porém é uma variável que mesmo não tendo uma grande influência, tem os ciclos de sazonalidade correspondentes as demais variáveis de entrada e a velocidade do vento, sendo utilizada para dar mais acurácia ao resultado final da previsão.

CAPÍTULO 4

4 RESULTADOS E DISCUSSÕES

4.1 TESTES DA PRIMEIRA ETAPA: ENCONTRAR O MELHOR ALGORITMO DE TREINAMENTO PARA O MODELO NARX (ESTAÇÃO DE BRB)

Foram utilizados 3 algoritmos de treinamento na rede NARX, no qual o Bayesian Regularization (BS), que na literatura é o algoritmo de treinamento que tem a melhor performance na convergência e resultados, se demonstrou verdadeiro também nos testes realizados, comparado aos algoritmos Levenberg-Marquard (LM) que também é muito utilizado e tem uma performance excelente e o Scaled Conjugate Gradient (SCG), a performance de cada algoritmo pode ser vista na Tabela 4.1.

A Tabela 4.1 apresenta os resultados dos testes realizados para o horizonte 1 dia com 5 passos à frente com a base de BRB, tendo como o melhor algoritmo em performance geral o BS, tendo menores erros MSE (1,280446), RMSE (1,131568) e com uma correlação de 93,2439%, sendo superior ao LM e ao SCG.

Na coluna “Erros” é apresentado os erros utilizados para medir a performance do algoritmo, a coluna “Horizonte” contém os tempos de previsão do algoritmo, que no caso foi utilizado para 1 dia, já a coluna “Passos à frente” é adicionada a quantidade de previsão que se deseja para o horizonte que no caso é 5, logo o cálculo para verificar o tempo de previsão pode ser calculado pela Eq. 4.1.

$$TP = H \times PF \quad (4.1)$$

Onde;

TP: Tempo de previsão;

H: Horizonte;

PF: Passos à frente.

Nas colunas LM, BS e SCG estão os valores alcançados por cada algoritmo de treinamento correspondente.


Tabela 4.1 - Resultado dos algoritmos de treinamento para o horizonte de 1 dia 5 passos à frente.

Erros	Horizonte	Passos à frente	LM	BS	SCG
MSE	1 dia	5	1,314434	1,280446	1,422129
RMSE	1 dia	5	1,146488	1,131568	1,192530
CORRELAÇÃO (%)	1 dia	5	93,0775	93,2439	92,4699

Fonte: AUTOR (2021).

Nos testes realizados no modelo de previsão NARX com a base de dados de BRB, o melhor algoritmo de treinamento foi o BS em termo de correlação, alcançando a melhor correlação dentre os outros algoritmos de treinamento testados com uma porcentagem de 93,2439%, conforme pode ser visto na Tabela 4.1. Em contrapartida o algoritmo SCG foi o que apresentou o pior desempenho de correlação, com um valor de 92,4699%, sendo válido ressaltar que o SCG teve a menor correlação em oito de nove testes realizados, isso pode ser visto no comparativo de regressão dos testes realizados que é mostrado no Gráfico 4.1.

Gráfico 4.1 - Comparativo de regressão do LM, BS e SCG (base de dados de BRB).




Fonte: AUTOR (2021).

Em relação ao Gráfico 4.1 é possível observar que o algoritmo de treinamento BS obteve as maiores correlações em todos os cenários testados em comparação com os algoritmos LM e SCG, alcançando as maiores correlações no horizonte de horas.

Para o erro MSE a melhor performance obtida foi o algoritmo BS com uma taxa de erro aproximada de 1,2804, em segundo lugar ficou o LM com um valor próximo de 1,3144 e em último o SCG com um resultado para o MSE em torno de 1,4221. O algoritmo BS obteve as menores taxas de erro MSE em todos os nove cenários testados, conforme pode ser observado no Gráfico 4.2.

Gráfico 4.2 - Comparativo de erros MSE do LM, BS e SCG (base de dados de BRB).




Fonte: AUTOR (2021).

Para o erro RMSE mostrado no Gráfico 4.3, o algoritmo BS apresentou os menores valores de erro nos nove cenários testados com a base de dados de BRB. O horizonte que teve menores taxas de erro foi o de hora, assim como o erro MSE apresentado no Gráfico 4.2 e a Regressão apresentada no Gráfico 4.1, os melhores resultados foram para o horizonte de hora.

Destaque negativo para o algoritmo SCG que nos testes levando em consideração o erro RMSE, foi o que apresentou maiores taxas de erro em oito dos nove cenários, sendo o menos indicado entre os algoritmos comparados (LM e BS) para ser utilizado em redes neurais recorrentes NARX na previsão de séries temporais com sazonalidade.

Gráfico 4.3 - Comparativo de erros RMSE do LM, BS e SCG (base de dados de BRB).



Fonte: AUTOR (2021).

Foram realizados nove testes com a base de BRB envolvendo diferentes horizontes de tempo de previsão, como minutos, hora e dia, visto que a base de dados possui algumas inconsistências, optou-se por selecionar uma base com a velocidade do vento mais alta e com menos erros. Após uma avaliação dos dados contidos no projeto SONDA, foi selecionado a base de PTR, que possui menos erros, menos espaços em branco e uma velocidade do vento maior se comparada com as demais encontradas no site do projeto SONDA, base esta que foi selecionada para ser utilizada no modelo híbrido proposto HW-NARX.

No Quadro 4.1 é mostrado a lista de estações encontradas no site do projeto SONDA, no qual a primeira coluna está o nome da estação e a sigla correspondente, na segunda coluna o estado ao qual a estação está localizada, na coluna “Latitude” e “Longitude” encontra-se as coordenadas da exata localização das estações, e por fim na última coluna está à altitude da estação.

Quadro 4.1 - Estações encontradas no projeto SONDA.

Estação (SIGLA)	UF	Latitude	Longitude	Alt.(m)
Belo Jardim (BJD)	PE	08° 22' 03" S	36° 25' 46" O	718
Brasília (BRB)	DF	15° 36' 03" S	47° 42' 47" O	1023
Cachoeira Paulista (CPA)	SP	22° 41' 22,65" S	45° 00' 22,28" O	574
Caicó (CAI)	RN	06° 28' 01" S	37° 05' 05" O	176
Campo Grande (CGR)	MS	20° 26' 18" S	54° 32' 18" O	677
Cuiabá (CBA)	MT	15° 33' 19" S	56° 04' 12" O	185
Ourinhos (ORN)	SP	22° 56' 55" S	49° 53' 39" O	446
Palmas (PMA)	TO	10° 10' 40" S	48° 21' 43" O	216
Petrolina (PTR)	PE	09° 04' 08" S	40° 19' 11" O	387
Rolim de Moura (RLM)	RO	11° 34' 54" S	61° 46' 25" O	252
São Luiz (SLZ)	MA	02° 35' 36" S	44° 12' 44" O	40
São João do Cariri (SCR)	PB	07° 22' 54" S	36° 31' 38" O	486
São Martinho da Serra (SMS)	RS	29° 26' 34" S	53° 49' 23" O	489
Triunfo (TRI)	PE	07° 49' 38" S	38° 07' 20" O	1123
Chapecó (CHP)	SC	27° 04' 48" S	52° 36' 52" O	700
Curitiba (CTB)	PR	25° 29' 43,6" S	49° 19' 52,35" O	891
Florianópolis (FLN)	SC	27° 36' 6,1" S	48° 31' 4,2" O	31
Joinville (JOI)	SC	26° 15' 09" S	48° 51' 28" O	48
Natal (NAT)	RN	05° 50' 12" S	35° 12' 23" O	58
Sombrio (SBR)	SC	29° 05' 44" S	49° 48' 48" O	15

Fonte: SONDA (2021).

Tendo em vista a análise de performance dos algoritmos de treinamento, o BS obteve os melhores resultados como foi visto anteriormente, logo o algoritmo de treinamento selecionado para ser aplicado no modelo proposto é o BS.


Notou-se que os resultados atingidos pelo algoritmo BS foram melhores que os concorrentes para a rede neural NARX, como foi visto no comparativo apresentado nos

Gráficos 4.1, 4.2 e 4.3, porém os resultados alcançados de erros do BS podem ser melhorados com ajustes na base de dados e melhorando a entrada dos dados com uma suavização nas quatro variáveis de entrada, esta que é uma característica do modelo proposto, modelo este que é abordado na próxima seção (4.2).

4.2 MODELO PROPOSTO HW-NARX

Na Figura 4.1 é apresentado a arquitetura do modelo proposto HW-NARX, modelo que pretende melhorar o modelo NARX por meio de suavização Exponencial de Holt-Winters.

Figura 4.1 - Arquitetura do modelo híbrido proposto HW-NARX.



Fonte: AUTOR (2021).

O modelo HW-NARX é uma proposta que tem a finalidade de melhorar a previsão da velocidade do vento. Nas variáveis independentes (entrada) são suavizadas pelo modelo estatístico Holt-Winters no qual é gerado uma saída composta pelas quatro variáveis, porém suavizadas, essas variáveis suavizadas são utilizadas como entrada na rede NARX juntamente com os dados reais da velocidade do vento (variável dependente), a saída da rede NARX será a previsão da velocidade do vento.

Variável Independente: As variáveis independentes são simplesmente as variáveis de entrada do modelo, que neste estudo que teve como premissa a previsão da velocidade do vento para geração de energia eólica, as variáveis de entrada selecionadas foram Pressão Atmosférica, Umidade Relativa do Ar, Direção do Vento e Temperatura do Ar. As variáveis de entrada

devem ser tratadas e normalizadas, a fim de deixar a base de dados a ser utilizada sem valores nulos ou qualquer erro de captação dos dados que geralmente ocorre nos anemômetros.

Variável Dependente: A variável dependente é o mesmo que variável de saída, é o alvo ao qual se quer alcançar no final da previsão, que neste caso é a velocidade do vento, vale evidenciar que a variável velocidade do vento e as demais são coletadas de uma estação, configurando-se assim uma previsão baseada no modelo pontual e não probabilístico, tendo em vista que é o modelo mais utilizado para previsão da velocidade do vento para a geração de energia eólica.

Holt-Winters: O modelo Holt-Winters é utilizado para suavizar os dados e assim deixar a curva de dados menos acentuada. A vertente do modelo Holt-Winters aplicado no modelo proposto é o aditivo, vertente esta trabalha melhor com uma base de dados que possui uma sazonalidade sem tendência, que é o caso do comportamento da velocidade do vento. Caso o modelo proposto seja aplicado para outras previsões é necessário averiguar se o modelo aditivo é a vertente adequada para a base de dados, caso não seja adequado utilizar a outra vertente do modelo HW (multiplicativo).

Saída Suavizada: Nesta saída gerada pelo algoritmo HW é armazenado os dados suavizados que se juntam a variável velocidade do vento, que servem como entrada no modelo NARX.

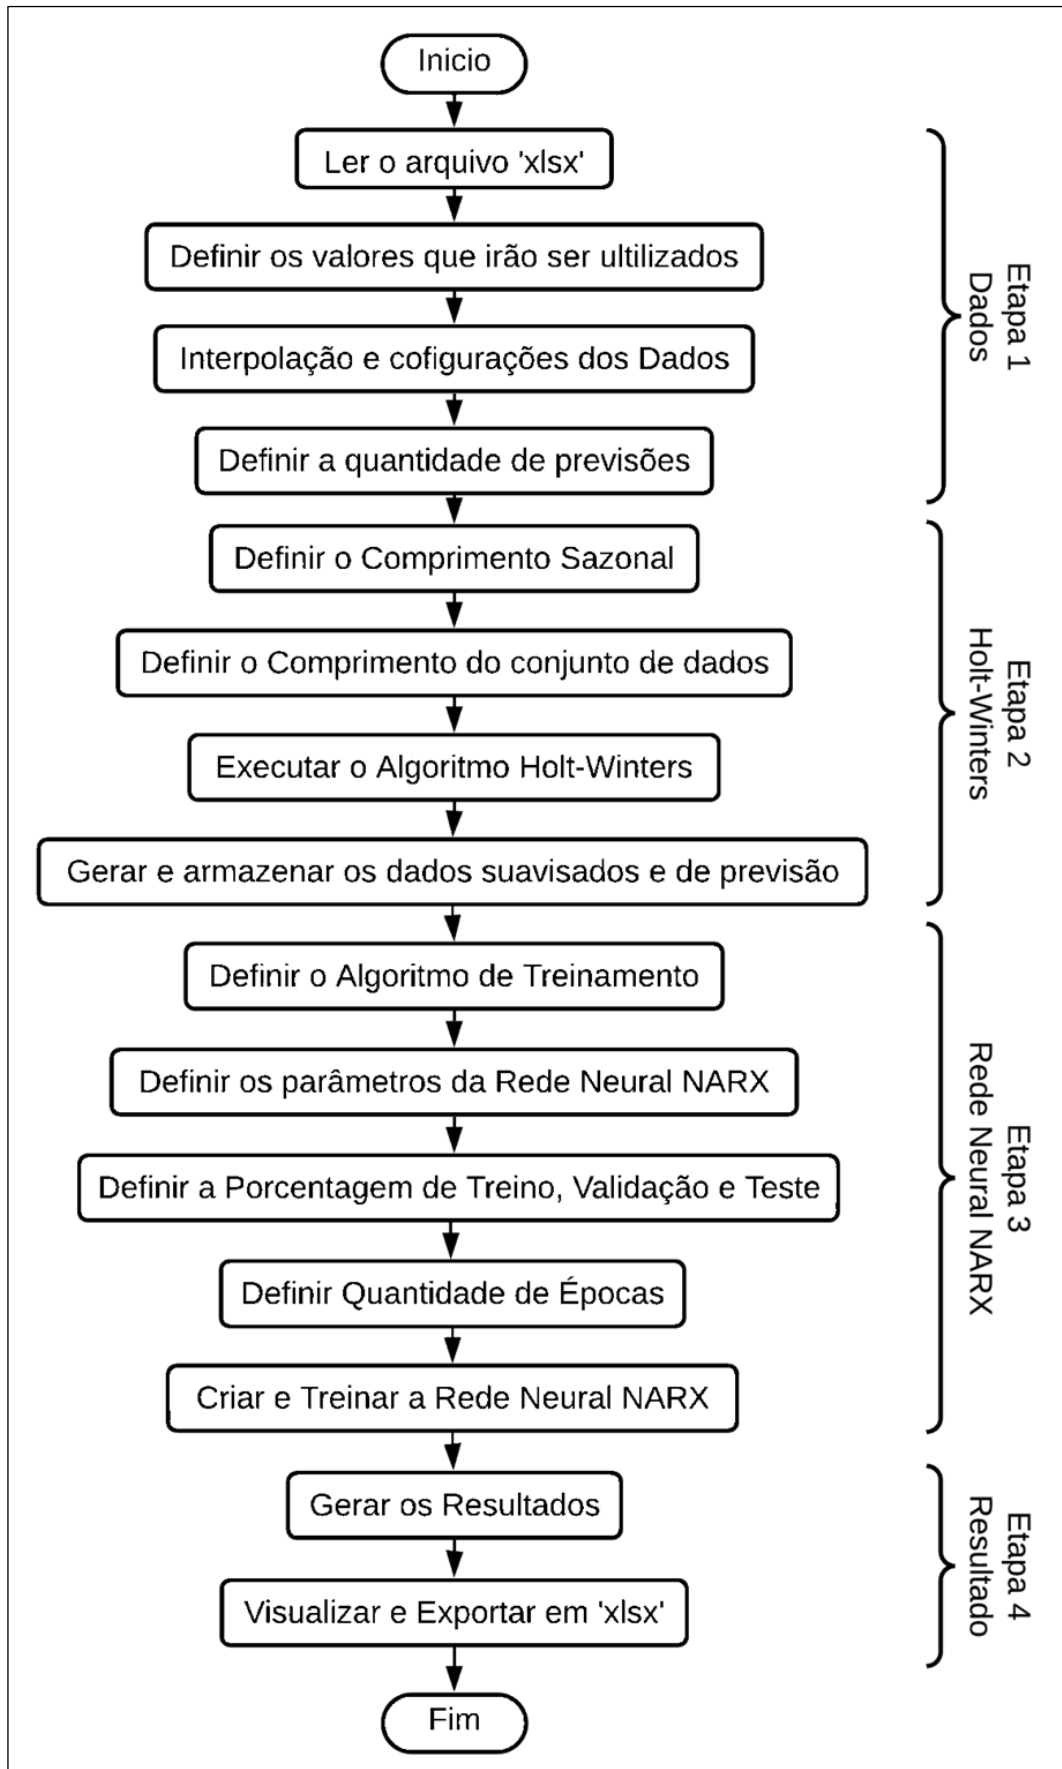
NARX: A rede neural recorrente NARX tem como entrada as variáveis dependentes suavizadas pelo HW e a velocidade do vento original, que são processadas pela rede neural utilizando o algoritmo de treinamento BS na camada oculta.

Resultado: Após passar por todas as etapas e o modelo NARX resultar a previsão da variável de saída (velocidade do vento), se tem o resultado final da previsão do modelo proposto.

4.2.1 Fluxograma do Modelo Proposto HW-NARX

Na Figura 4.2 encontra-se o fluxograma do modelo proposto HW-NARX, no qual é separado por quatro etapas, sendo elas intituladas de Dados, Holt-Winters, Rede Neural NARX e Resultado, o fluxograma apresentado dispõem ainda de 15 subprocessos do algoritmo desenvolvido no *Matlab*® 2016a, no qual é implementado o algoritmo híbrido proposto HW-NARX juntamente com o modelo HW e NARX para efeito de comparação.

Figura 4.2 - Fluxograma do algoritmo proposto HW-NARX.



Fonte: AUTOR (2021).

Etapa 1 - Dados:

- O primeiro passo do algoritmo desenvolvido para executar o algoritmo proposto da unificação de HW e NARX é ler a planilha com a base de dados em formato “xlsx”, contendo as variáveis de entrada separadas por coluna, ao qual não é necessário a inclusão da coluna “Data”, é necessário que todas as colunas estejam com as tuplas em formato numérico, exceto a primeira linha que deve ser classificada como “string”, podendo ser definido com qualquer nome incluindo caracteres especiais, a primeira linha do arquivo serve para nomear as variáveis.
- Após a leitura do arquivo da base de dados, o próximo passo é definir as colunas que irão ser utilizadas como variáveis de entrada e saída, bem como a quantidade de registro a ser utilizado nas variáveis selecionadas. Como forma de exemplo no trabalho desenvolvido foi aplicado para o horizonte de tempo de 10 minutos a 5, 10 e 30 passos à frente a quantidade utilizada foi de 4300 registros, a quantidade de dados fica a cargo do usuário definir.
- A próxima fase é fazer a interpolação na base de dados se necessário, para retirar os valores ou registros que tiverem valores numéricos igual a zero ou qualquer valor que pode ser definido pelo usuário. Entre as configurações possíveis estão as possibilidades de limitar a quantidade de registros a serem utilizados ou até mesmo agrupar um conjunto de dados, por exemplo, caso a base de dados estejam em uma unidade de tempo (minutos) e se queira agrupar 60 registros e tira uma média desses dados formando um registro apenas é possível, e a partir daí uma base que está em uma determinada unidade de tempo pode ser transformar em outra unidade de forma rápida e simples, facilitando a previsão para diferentes horizontes de tempo.
- O último passo da etapa 1 é definir a quantidade de previsões a serem feitas, no trabalho em questão foram utilizados para o horizonte de 10 minutos os valores 50, 100 e 300 como parâmetro de previsão.

Etapa 2 – Holt-Winters:

- A segunda etapa do algoritmo começa com a definição do comprimento sazonal dos dados que é definido pelo usuário, o comprimento sazonal que é um parâmetro do algoritmo Holt-Winters, pode ser conceituado como o intervalo de dados no qual ocorre a sazonalidade. Cabe ao usuário encontrar o comprimento

sazonal de sua base de dados, no trabalho desenvolvido o comprimento de sazonalidade para o horizonte de 1 semana a trinta passos à frente foi de 52 registros (semanas), tal valor pode ser encontrado observando o comportamento do vento ao longo do tempo, conforme pode ser observado na Gráfico 4.4.

Gráfico 4.4 - Sazonalidade do Horizonte de 1 Semana (Base de dados de PTR).



Fonte: AUTOR (2021).

- O segundo passo é definir o comprimento da sazonalidade no conjunto de dados utilizados, no exemplo do Gráfico 4.4 é possível verificar que o comprimento de sazonalidade é de 52 semanas, pois é o número de vezes que a sazonalidade se repete ao longo do conjunto de dados.
- Após ter colocado os parâmetros do algoritmo Holt-Winters, o mesmo é executado, tendo seus dados armazenados em um arquivo “*xlsx*”, dados como os valores de Alfa (α), Beta (β) e Gama (γ). É válido informar mais uma vez que o algoritmo implementado para o Holt-Winters foi a vertente conhecida como aditiva, pois foi a que se adequou para o problema de previsão da velocidade do vento.
- Para efeito de comparação, no quarto e último passo da etapa 2 são gerados e armazenados os dados de previsão do HW e para o propósito maior que é o algoritmo híbrido proposto, são armazenados os dados suavizados, para que possam ser utilizados na rede neural recorrente NARX, que será descrito na etapa 3.

Etapa 3 – Rede Neural NARX:

- O primeiro passo é definir o algoritmo de treinamento da rede neural NARX, como foi visto anteriormente, o algoritmo selecionado para a previsão da

velocidade do vento do modelo híbrido proposto foi o BS. No algoritmo foi implementado 12 algoritmos de treinamento sendo eles: *Levenberg-Marquardt*, Regularização Bayesiana, *BFGS Quasi-Newton*, *Resilient Backpropagation*, *Scaled Conjugate Gradient*, *Conjugate Gradient with Powell/Beale Restarts*, *Fletcher-Powell Conjugate Gradient*, *Polak-Ribière Conjugate Gradient*, *One Step Secant*, *Variable Learning Rate Gradient Descent*, *Gradient Descent with Momentum*, *Gradient Descent*. Tais algoritmos ficam à disposição para que o usuário selecione o melhor para o problema a ser resolvido, em caso de não saber qual o algoritmo utilizar o usuário pode escolher todos os algoritmos, que fará o NARX executar um algoritmo de cada vez, tendo assim vários resultados, um para cada algoritmo testado.

- O segundo passo é definir os parâmetros da rede neural NARX, sendo eles a quantidade de camadas ocultas e neurônios das camadas ocultas, para o modelo híbrido foi utilizado uma camada oculta com 10 neurônios (Padronizado para todos os cenários).
- Após ter definido e aplicado os parâmetros do NARX, é necessário definir a quantidade de dados (em porcentagem %) a ser utilizados para cada etapa do processo de previsão, sendo eles divididos em Treinamento, Validação e Teste. O padrão é 70% dos dados destinados ao treinamento, 15% para a validação e 15% para os testes, que foi a configuração empregada no modelo proposto, como o algoritmo de treinamento selecionado para o modelo proposto HW-NARX foi o BS que não possui o processo de validação, assim os dados destinados para a validação são ignorados.
- O quarto e último passo da etapa 3 é definir a quantidade de épocas limite para que o algoritmo pare de processar a rede neural, limite este é alcançado caso o algoritmo de previsão não encontre um valor de convergência dentro do limite de ciclos (épocas).

Etapa 4 – Resultado:

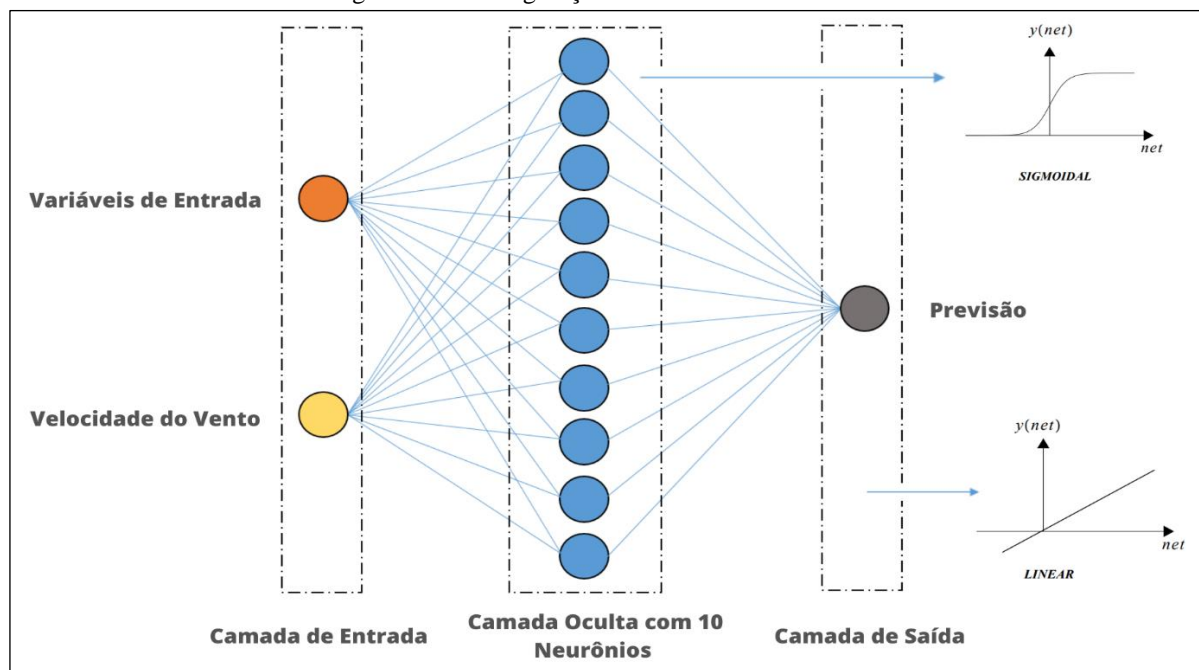
- A etapa 4 é a última do algoritmo desenvolvido e o primeiro passo dessa etapa é a geração dos resultados. Resultados estes da previsão da velocidade do vento, que foram alcançados por meios da inclusão de dados suavizados nas variáveis de entrada.

- O último passo é a geração de vários arquivos “*xlsx*” com os dados da previsão do modelo híbrido proposto, bem como dados do modelo HW e NARX para efeito de comparação dos modelos.

4.3 Testes da Segunda Etapa: Modelo Híbrido Proposto HW-NARX (Estação de PTR)

Na Figura 4.3 é apresentado o modelo com as configurações do experimento utilizadas para a segunda etapa de testes, que foi a mesma configuração utilizada para encontrar o melhor algoritmo de treinamento para o NARX (primeira etapa de testes).

Figura 4.3 - Configurações da Rede Neural NARX.



Fonte: AUTOR (2021).

Como configurações da rede neural NARX foi utilizado uma camada oculta com 10 neurônios tendo a camada uma função de ativação sigmoide e na camada de saída uma função linear. Como entrada foi inserido as variáveis Temperatura, Umidade, Pressão e Direção do vento, também na camada de entrada foi inserido o alvo (Velocidade do Vento).

Na segunda etapa de testes realizados com os modelos HW, NARX e o modelo híbrido proposto HW-NARX, foi utilizado a base de dados do projeto SONDA da estação de PTR, devido à base de dados de BRB utilizada na primeira etapa de testes para alcançar uma boa configuração de uma rede neural NARX obteve algumas inconsistências. Já tendo alcançado uma configuração da rede neural, optou-se por utilizar uma outra base de dados (base de PTR) com menos inconsistências e maiores velocidades de vento.

Foram realizados testes de previsão da velocidade do vento com os modelos HW, NARX e o modelo proposto HW-NARX, tendo como horizontes de previsão a ultracurto prazo de 10 minutos com 5, 10 e 30 passos à frente, ou seja, 50 minutos, 100 minutos e 300 minutos a frente, utilizando uma base de dados na mesma unidade de medida de tempo (Minutos).

Para o horizonte a curto prazo de uma hora foram empregados 5, 10 e 30 passos à frente, totalizando os tempos de previsão de 5 horas, 10 horas e 30 horas à frente. O horizonte de médio prazo foi previsto para um dia com 5, 10 e 30 passos à frente, sendo 5, 10 e 30 dias respectivamente. Para o horizonte de longo prazo a uma semana com 5, 10 e 30 passos à frente foi previsto, sendo 5, 10 e 30 semanas de previsão respectivamente. As ressalvas estão voltadas para a unidade de medida utilizada em cada horizonte de tempo, no horizonte de dias, foi utilizado a unidade de tempo correspondente (dia), para os outros horizontes de tempo seguiu-se o mesmo padrão.

Na Tabela 4.2 é mostrado os valores utilizados como parâmetro para a suavização das variáveis, os valores foram alcançados através de algoritmo de busca, responsável por encontrar os valores que possuem menores erros MSE. Na Tabela 4.2 é mostrado os valores para o horizonte de 10 minutos 5 passos à frente, os valores utilizados para os outros horizontes de tempo testados (horizonte de 10 minutos 5, 10 e 30 passos à frente, horizonte de 1 hora 5, 10 e 30 passos à frente, horizonte de 1 dia 5, 10 e 30 passos à frente e horizonte de 1 semana 5, 10 e 30 passos à frente) estão disponibilizados nos gráficos do Apêndice C intitulado de “PARÂMETROS UTILIZADOS NO ALGORITMO HOLT-WINTERS PARA A SUAUIZACÃO E PREVISÃO DA VELOCIDADE DO VENTO”, vale ressaltar que os valores utilizados para o treinamento foram os mesmos usados na previsão pelo algoritmo HW.

Tabela 4.2 - Parâmetros utilizados para suavização das variáveis.


Variáveis	Alfa	Beta	Gama
Temperatura	1,000522	0,000765	0,837095
Umidade	0,999899	0,000509	-0,17935
Pressão	1,000302	0,000423	-0,2078
Direção	1,000037	0,00003712	-0,25069
Velocidade	1,024329	0,000332	1,002059

Fonte: AUTOR (2021).

No Gráfico 4.5 é mostrado um comparativo da rede neural NARX com o modelo híbrido proposto, onde pode-se notar que os percentuais de regressão são próximos, sendo os horizontes de dia e semana os que conseguiram alcançar maiores percentuais de correlação, tanto para o modelo proposto quanto para o modelo NARX, ambos atingindo percentuais maiores que 0,89.

O comparativo de regressão mostrado no Gráfico 4.5 é a média das regressões de treino e testes da rede neural, não está incluso a regressão da previsão de cada horizonte.

Gráfico 4.5 - Comparativo de regressão entre o modelo NARX e o modelo proposto.



Fonte: AUTOR (2021).


Além do comparativo feito entre as correlações das variáveis utilizadas pelo modelo NARX e o modelo proposto HW-NARX levando em consideração treino e teste, também foi realizado o comparativo entre a quantidade de épocas realizadas pelo algoritmo NARX e o modelo proposto HW-NARX para alcançarem os resultados dos testes feitos pelas Redes neurais, no qual pode ser observado no Gráfico 4.6.

Observando o Gráfico 4.6 é possível identificar que o horizonte ao qual o modelo proposto convergiu mais rápido fazendo menos iterações foi para o horizonte de tempo de 10 minutos 5 passos à frente, com 103 épocas, o modelo NARX para este mesmo horizonte alcançou 142 épocas.

O pior cenário para o HW-NARX foi para o horizonte de 1 semana 10 passos à frente, no qual atingiu 1000 épocas, que foi o limite máximo estabelecido para que a rede treinasse. Já o NARX precisou apenas de 142 épocas para convergir.

No geral o modelo híbrido proposto HW-NARX convergiu mais rápido que o NARX, alcançando menos épocas em oito cenários dos doze possíveis, em que o destaque foi o horizonte de hora, precisando de menos épocas para convergir em todos os três cenários testados deste horizonte.

Gráfico 4.6 - Comparativo de épocas entre o modelo NARX e o modelo proposto.



Fonte: AUTOR (2021).

Com a análise feita do comparativo de regressão e quantidade de épocas dos horizontes testados para o modelo proposto HW-NARX e a rede neural recorrente NARX, a próxima seção (4.3.1) aborda a análise do comparativo de erros de performance e previsibilidade de todos os horizontes testados dos modelos HW, NARX e o modelo proposto HW-NARX, tendo como parâmetros os erros MSE, RMSE e MAPE.

4.3.1 Análise do Comparativo de Erros de Performance e Previsibilidade

Nesta seção é explorado apenas os erros obtidos a partir da previsão da velocidade do vento, os erros obtidos do treinamento não estão sendo explorados nesta seção, no Apêndice B intitulado de “COMPARATIVO DE ERROS MSE, RMSE E MAPE DE PERFORMANCE DE TREINAMENTO PARA OS ALGORITMOS NARX E O MODELO PROPOSTO HW-NARX” é exposto os gráficos do comparativo entre o modelo proposto e o modelo NARX dos erros (MSE, RMSE e MAPE) em relação ao treinamento das redes neurais.

4.3.1.1 Horizonte de 10 Minutos

No Gráfico 4.7 é apresentado o resultado dos erros da previsão do modelo proposto HW-NARX, o modelo de rede neural recorrente NARX e o HW em relação ao horizonte de tempo


de 10 minutos com 5 passos à frente, ao qual são comparados em relação aos erros MSE, RMSE e MAPE. O Gráfico 4.7 mostra que o erro MSE foi menor no modelo proposto, com um valor aproximado de 0,6224 de taxa de erro, enquanto que o modelo NARX obteve uma de taxa de erro MSE de aproximadamente 1,4103, já o algoritmo Holt-Winters atingiu um valor de erro de aproximadamente 1,9057. Assim o modelo HW atingiu o maior erro tendo a pior performance para o MSE.

Em relação ao erro RMSE o modelo proposto teve uma taxa de perto de 0,7890, enquanto o modelo NARX teve um valor aproximado de 1,1876, para o modelo HW a taxa de erro ficou próxima de 1,3805. Nesta análise comparativa do Gráfico 4.7 o HW teve a pior performance para o erro RMSE e o modelo proposto alcançou a melhor performance.

Na comparação do erro MAPE o melhor algoritmo foi o modelo proposto, pois atingiu uma menor taxa de erro se comparado ao NARX e HW, o modelo proposto atingiu uma taxa de erro aproximada de 10,8202 e o NARX teve um valor aproximado de 18,6252, enquanto que o HW atingiu um valor para o erro MAPE de 16,5907. Logo o algoritmo que teve a melhor performance no horizonte de tempo de 10 minutos a cinco passos à frente foi o modelo híbrido proposto HW-NARX, tendo valores de erros menores em todos os erros comparados (MSE, RMSE e MAPE).

Gráfico 4.7 - Comparativo de erros (Horizonte de 10 minutos 5 passos à frente).

Horizonte de 10 Minutos 5 passos à frente



Fonte: AUTOR (2021).

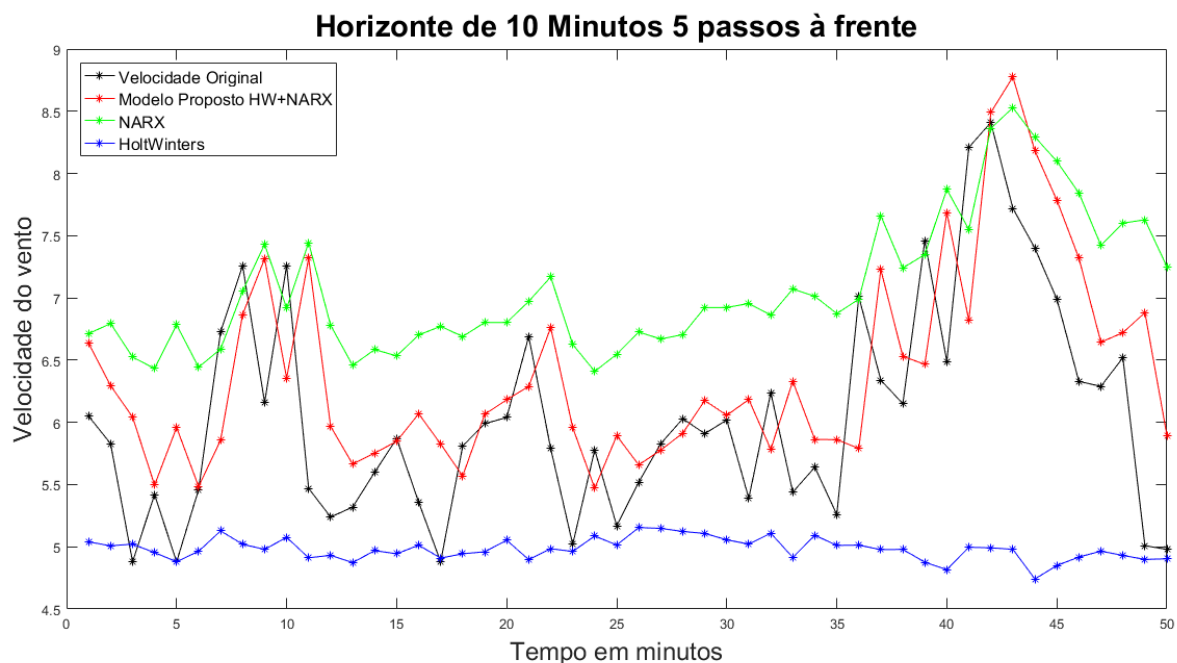
O Gráfico 4.8 apresenta um comparativo entre a previsão dos modelos HW, NARX e o modelo proposto com a velocidade do vento original, no qual é comparado o horizonte de tempo de 10 minutos a 5 passos à frente, ou seja, 50 minutos à frente. É possível observar com o

comportamento da velocidade do vento ao longo dos 50 minutos de previsão, que o modelo HW obteve a pior previsão entre os algoritmos comparados, seguindo uma velocidade quase constante com uma velocidade do vento de 5 m/s.

O modelo NARX alcançou o segundo lugar para este horizonte com um comportamento com valores a quase todos os instantes acima do valor real da velocidade do vento e do modelo proposto.

A melhor previsão para este horizonte de tempo a 10 minutos com 5 passos à frente foi o modelo proposto, tendo um comportamento mais espelhado com a velocidade original se comparado com os algoritmos testados, conforme pode ser observado no Gráfico 4.8.

Gráfico 4.8 - Comparativo de previsão (Horizonte de 10 minutos 5 passos à frente).



Fonte: AUTOR (2021).

O Gráfico 4.9 apresenta um comparativo de erros de performance MSE, RMSE e MAPE em relação ao algoritmo híbrido proposto, NARX e HW para o horizonte de tempo de 10 minutos com 10 passos à frente. No comparativo de performance do erro MSE, o algoritmo proposto HW-NARX teve uma taxa de erro de aproximadamente 1,4388, enquanto que o NARX obteve uma taxa de erro maior se aproximando de 2,5881, já o HW obteve um valor de erro próximo de 4,6473, sendo assim o algoritmo proposto teve uma melhor performance neste erro, já que o erro foi menor que o modelo NARX e o modelo HW.


Comparando os três modelos para o erro RMSE, o modelo HW-NARX alcançou uma taxa de erro perto de 1,1995, o NARX se aproximou de uma taxa de erro de 1,6087, enquanto

que o algoritmo HW atingiu uma taxa de erro próxima a 2,1557, possuindo um maior erro e tendo uma performance pior que os modelos NARX e o modelo proposto para o erro RMSE, enquanto que o modelo proposto alcançou o menor e conseqüentemente o melhor desempenho.

Observando o Gráfico 4.9 nota-se que para o erro MAPE o algoritmo proposto apresentou um erro aproximado de 18,9896, para o NARX o erro foi muito maior com uma taxa de 27,2760, assim como o HW que alcançou um erro MAPE que se aproxima de 29,5349. Sendo assim o algoritmo proposto HW-NARX teve uma melhor performance em todos os erros comparados e devido a isto alcançou um melhor desempenho se comparado com o algoritmo NARX e HW para o horizonte de tempo de 10 minutos com 10 passos à frente, ou seja, 100 minutos de previsão à frente.

Gráfico 4.9 - Comparativo de erros (Horizonte de 10 minutos 10 passos à frente).

Horizonte de 10 Minutos 10 passos à frente




Fonte: AUTOR (2021).

A comparação da previsão da velocidade do vento para o horizonte de 10 minutos a 10 passos à frente dos modelos HW, NARX e o modelo proposto HW-NARX pode ser observado no Gráfico 4.10, que nota-se que o HW dentre os modelos comparados foi o que apresentou uma maior variância na amplitude (altura) da sazonalidade, como a velocidade original para este comparativo apresentou um comportamento mais linear e com menos variância na amplitude da sazonalidade, o modelo HW foi o que apresentou menor eficácia na previsão ao longo dos 100 minutos.

O algoritmo NARX apresentou um comportamento ao longo do tempo destoante da velocidade original, com os valores muito lineares em relação a velocidade original, sendo que o comportamento da linha de previsão do NARX não se comporta de forma a imitar a variância da amplitude da velocidade original.

O comportamento da linha de previsão da velocidade do vento feita pelo algoritmo proposto tende a imitar de maneira mais adequada e próxima a linha da velocidade original, estando mais próxima da linha da velocidade original ao longo dos minutos do que os algoritmos HW e NARX. Assim, o algoritmo vencedor em previsibilidade da velocidade do vento para o horizonte de 10 minutos a 10 passos à frente é o HW-NARX.

Gráfico 4.10 - Comparativo de previsão (Horizonte de 10 minutos 10 passos à frente).



Fonte: AUTOR (2021).

O Gráfico 4.11 mostra o comparativo entre os algoritmos HW-NARX, NARX e o HW levando em consideração a taxa de erros entre os erros de performance MSE, RMSE e MAPE, que são comparados no horizonte de 10 minutos a 30 passos à frente, que é o mesmo que 300 minutos à frente.

Na comparação dos algoritmos, relativo ao erro MSE, o modelo proposto atingiu uma taxa de erro de aproximadamente 1,6260, o modelo NARX chegou a um erro aproximado de 2,1934 e o algoritmo HW chegou a uma taxa de erro ainda maior com aproximadamente 7,0177, sendo um erro superior ao modelo proposto. Analisando os dados contidos no Gráfico 4.11 pode-se observar que o modelo proposto HW-NARX foi que obteve um desempenho melhor, devido a taxa de erro ser mais baixa que as demais.


O modelo proposto atingiu um erro RMSE próximo de 1,2751, enquanto que o modelo NARX obteve um valor de taxa de erro próxima de 1,4810, já o HW alcançou um valor próximo

de 2,6491 fazendo com que o modelo HW-NARX tenha tido uma melhor performance de erro RMSE.

Para o erro MAPE, o algoritmo proposto teve um valor de erro perto de 16,5027, já a rede neural recorrente NARX conseguiu um erro aproximado de 19,9837, enquanto que o algoritmo HW teve uma taxa aproximada de 26,5070, logo pode-se concluir que a melhor performance entre os algoritmos NARX, HW e o HW-NARX em relação aos erros MAPE, MSE e RMSE é o modelo proposto HW-NARX com menores erros.

Gráfico 4.11 - Comparativo de erros (Horizonte de 10 minutos 30 passos à frente).

Horizonte de 10 Minutos 30 passos à frente



Fonte: AUTOR (2021).

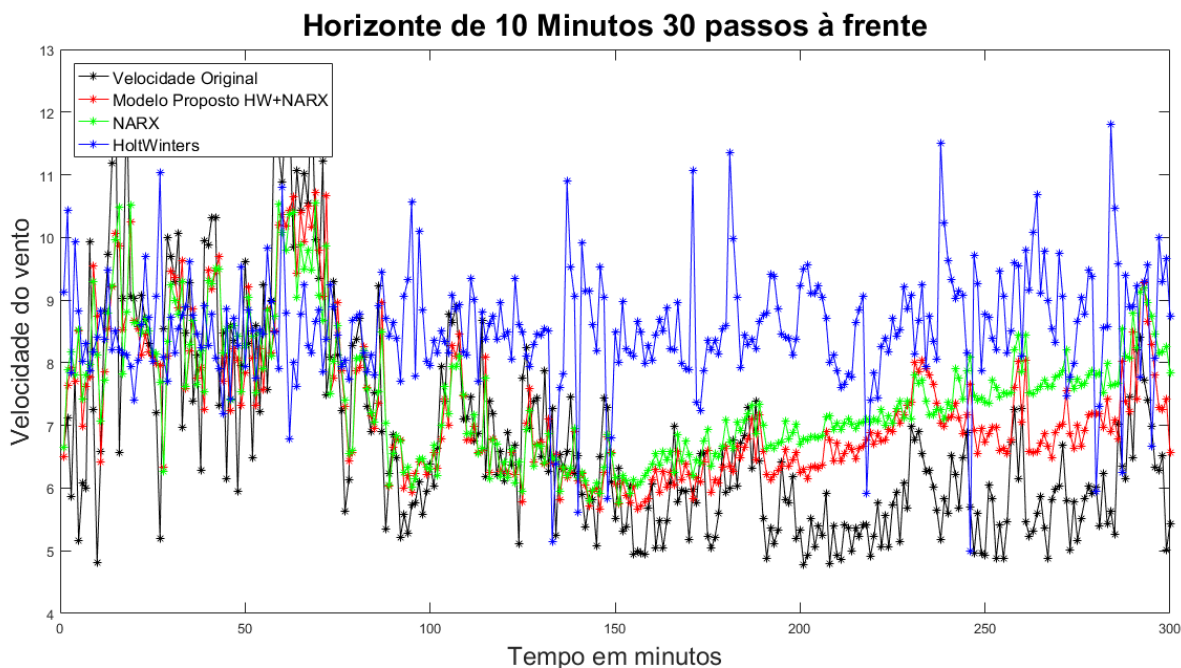
O comparativo de previsões em relação a velocidade original entre os algoritmos HW, NARX e o modelo HW-NARX para o horizonte de tempo de 10 minutos com 30 passos à frente pode ser visualizado no Gráfico 4.12, no qual é possível notar que o HW tem a pior previsibilidade da velocidade do vento entre os algoritmos comparados, tendo um comportamento razoável, seguindo a linha da velocidade original no intervalo de 1 a 73 minutos, porém se perdendo no restante dos minutos sem conseguir prever sequer o comportamento da amplitude da velocidade do vento original.

A rede neural NARX teve um bom comportamento do minuto 1 ao 193, porém após este intervalo a linha de previsão do modelo se distanciou da velocidade do vento original sem perder o comportamento da amplitude e variância.

A melhor performance de linha de previsão foi obtida pelo modelo proposto HW-NARX, no qual conseguiu imitar de forma mais espelhada o comportamento da velocidade do vento original, se comparado aos algoritmos concorrentes. O modelo proposto teve um

comportamento muito semelhante ao NARX, a diferença ocorreu no distanciamento da amplitude entre as linhas de previsão, em que o NARX se distanciou mais que o modelo híbrido proposto, conforme pode ser observado no Gráfico 4.12 no intervalo entre 193 e 300 minutos, onde a linha de previsão do modelo HW-NARX está mais próxima da velocidade original.

Gráfico 4.12 - Comparativo de previsão (Horizonte de 10 minutos 30 passos à frente).



Fonte: AUTOR (2021).

Analisando os dados de erros do horizonte de 10 minutos, obteve-se como resultado final para este horizonte uma melhor performance de taxa de erros MSE, RMSE e MAPE, o algoritmo híbrido proposto HW-NARX, no qual atingiu melhores resultados para todos os cenários testados (5, 10 e 30 passos à frente).

Para os resultados das previsões, o melhor algoritmo também foi o modelo proposto HW-NARX, que atingiu melhores previsões em todos os cenários testados (5, 10 e 30 passos à frente). Com isso, o melhor algoritmo testado para este horizonte de tempo (ultracurto prazo) de 10 minutos é o algoritmo proposto HW-NARX.

4.3.1.2 Horizonte de 1 Hora

O Gráfico 4.13 contém um comparativo de erros de performance entre os algoritmos de previsão de séries temporais NARX, HW e o modelo proposto HW-NARX para o horizonte de 1 hora 5 passos à frente da velocidade do vento, tendo como modelos de erros para a comparação o MSE, RMSE e o MAPE.

Analisando o Gráfico 4.13 para o erro MSE, nota-se que o modelo proposto HW-NARX aproximou-se de uma taxa de erro de 0,2998, o modelo de previsão NARX alcançou um valor parecido ao do modelo proposto com aproximadamente 0,2512, enquanto que o algoritmo HW atingiu uma menor taxa de erros se comparado com os algoritmos testados, alcançando um valor próximo de 0,2097, logo o HW teve a melhor performance para o erro MSE. Sendo que o modelo proposto teve o pior resultado para este erro.

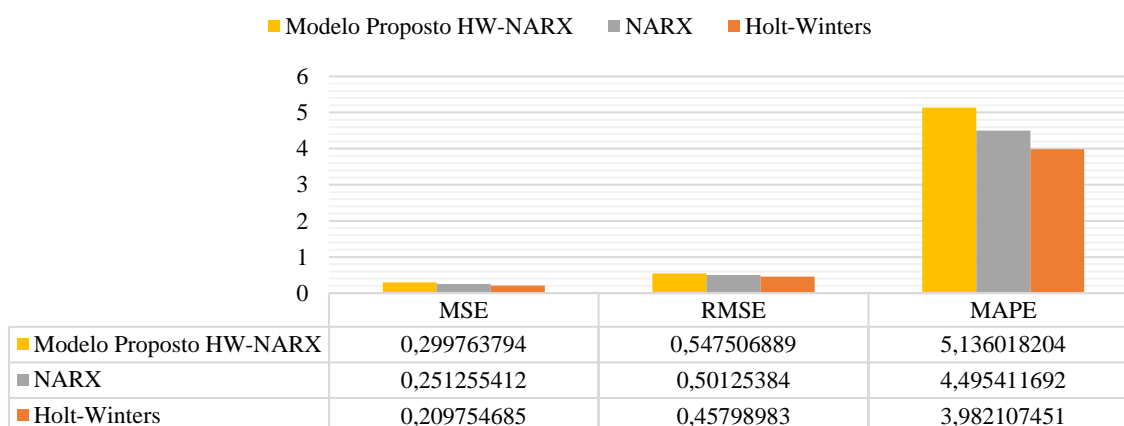
Para o comparativo de erros em relação ao RMSE, o algoritmo híbrido HW-NARX obteve um valor aproximado de 0,5475, o modelo NARX atingiu uma taxa de erro aproximada de 0,5012, enquanto que o modelo HW conseguiu alcançar um menor erro em relação aos demais, tendo seu valor perto de 0,4580, consistindo no algoritmo com a melhor performance para o erro RMSE. O modelo HW-NARX teve a maior taxa de erro.

Em relação ao erro MAPE, o modelo HW-NARX atingiu um valor de erro aproximado a 5,1360, sendo o algoritmo com a pior performance testada, o modelo NARX alcançou uma taxa aproximada de 4,4954, enquanto que o algoritmo HW chegou a uma taxa menor em relação aos demais algoritmos testados, alcançando um valor de 3,9821, sendo o modelo com a melhor performance para o erro MAPE.

Logo o algoritmo que obteve a melhor performance para o horizonte de 1 hora 5 passos à frente foi o modelo HW, que alcançou menores valores nos três erros utilizados para a comparação MSE, RMSE e MAPE.

Gráfico 4.13 - Comparativo de erros (Horizonte de 1 hora 5 passos à frente).

Horizonte de 1 Hora 5 passos à frente



Fonte: AUTOR (2021).

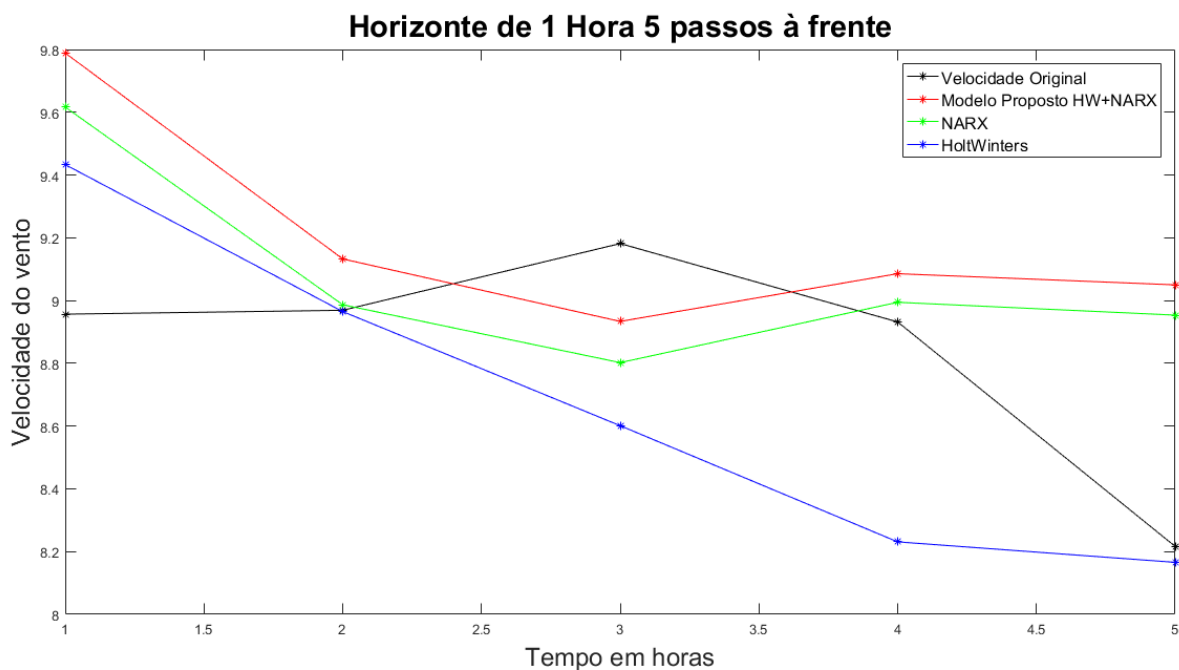
O Gráfico 4.14 exibe o comparativo das linhas de previsões dos algoritmos HW, NARX e o modelo proposto HW-NARX em relação à velocidade original do vento. O algoritmo HW

teve um comportamento melhor se comparado aos demais, tendo alcançado valores mais próximos ao da velocidade original ao longo do tempo, atingindo melhores valores que os concorrentes nos pontos de previsão de 1 hora, 2 horas e 5 horas.

O modelo NARX teve um comportamento da linha de previsão similar ao modelo HW-NARX, sendo melhor que os concorrentes apenas na hora 4, com um valor da velocidade do vento aproximado de 9 m/s, chegando muito próximo ao valor real da velocidade do vento.

Já o modelo proposto não se saiu bem no comportamento da linha de previsão da velocidade do vento, tendo o melhor resultado na hora 3, e mesmo assim não tão próximo da velocidade original quanto o modelo NARX, devido a esta análise do Gráfico 4.14 pode-se verificar que o modelo proposto teve a pior performance no comportamento da velocidade do vento para o horizonte de 1 hora 5 passos à frente.

Gráfico 4.14 - Comparativo de previsão (Horizonte de 1 hora 5 passos à frente).



Fonte: AUTOR (2021).

No Gráfico 4.15 encontra-se um comparativo de performance entre os algoritmos de previsão com sazonalidade HW, NARX e o modelo proposto HW-NARX, no qual são utilizados os erros MSE, RMSE e MAPE para a comparação de desempenho entre os modelos no horizonte de tempo de 1 hora 10 passos à frente.

Na comparação de desempenho do erro MSE, o modelo proposto alcançou uma taxa de erro aproximada de 1,6553, sendo a pior performance para o horizonte de 1 hora 10 passos à frente, levando em consideração apenas o erro MSE. Para o modelo NARX o desempenho foi

melhor que o modelo proposto, atingindo um valor próximo de 1,6120, enquanto que o algoritmo HW chegou a uma melhor performance tendo um menor erro MSE, erro com um valor aproximado de 0,6530.


Para o erro RMSE o modelo HW-NARX alcançou uma taxa maior que os demais algoritmos testados, atingindo uma taxa de erro próxima a 1,2866 e sendo a pior performance da lista para o erro RMSE. A rede neural recorrente NARX se aproximou de uma taxa de erro de 1,2696, superando o modelo proposto. Porém o algoritmo que obteve a melhor performance foi o HW que chegou a uma taxa de erro menor se comparado aos concorrentes, sendo o valor aproximado de 0,8081 para o erro RMSE.

Na comparação do erro MAPE o modelo proposto também teve o maior erro entre os algoritmos, alcançando uma taxa de 11,1806, já o modelo NARX alcançou uma taxa de erro próxima ao modelo proposto, porém menor com um valor de 11,1434. O HW foi o vencedor em desempenho na comparação do erro MAPE, com um erro próximo de 9,2571.

Na análise feita do Gráfico 4.15, o modelo com a melhor performance entre os algoritmos comparados HW, NARX e o modelo proposto HW-NARX, foi o HW alcançando menores erros tanto no MSE, RMSE como também no MAPE. Destaque negativo para o modelo proposto no horizonte de 1 hora 10 passos à frente, pois foi o que apresentou maiores erros no MSE, RMSE e MAPE.

Gráfico 4.15 - Comparativo de erros (Horizonte de 1 hora 10 passos à frente).

Horizonte de 1 Hora 10 passos à frente




Fonte: AUTOR (2021).

No Gráfico 4.16 é apresentado o comparativo dos algoritmos HW, NARX e o modelo proposto HW-NARX com a velocidade do vento original para o horizonte de tempo de 1 hora 10 passos à frente.

O modelo HW teve a melhor performance na comparação das linhas de previsão entre os algoritmos, pois o gráfico das linhas de previsões tem total correlação com os erros MSE, RMSE e MAPE, como o HW foi o que apresentou menores taxas de erro que os outros algoritmos testados, logo o mesmo tem uma linha de previsão melhor. O comportamento da linha de previsão do HW é melhor se comparada aos demais algoritmos também de forma visual, no qual ao longo do tempo é a linha de previsão que mais se aproxima da velocidade original do vento.

O modelo NARX teve um comportamento da linha de previsão muito próxima ao do modelo proposto HW-NARX, não sendo fácil de diferenciar qual teve o melhor comportamento da linha de previsão, para diferenciar tal comportamento e aferir qual obteve a melhor previsão, é necessário consultar o gráfico de erros que se encontra no gráfico anterior (Gráfico 4.15), o qual pode-se observar que o NARX por uma pequena diferença nos erros, foi o que apresentou melhores resultados. Logo, a pior linha de previsão é a do modelo proposto, ao qual teve maiores erros.

Gráfico 4.16 - Comparativo de previsão (Horizonte de 1 hora 10 passos à frente).



Fonte: AUTOR (2021).

O Gráfico 4.17 exibe o comparativo dos erros MSE, RMSE e MAPE dos algoritmos de previsão de séries temporais HW, NARX e o modelo HW-NARX, no qual são comparados em relação ao horizonte de 1 hora 30 passos à frente.

Nos testes realizados para o modelo proposto HW-NARX em relação ao erro MSE, o algoritmo alcançou um valor aproximado de 0,3467, já o modelo NARX obteve uma taxa de erro aproximada de 0,3204, no qual foi menor que o modelo proposto. Para o HW o erro MSE ficou em torno de 0,5604, representando a pior performance entre os algoritmos.


Em relação ao erro RMSE, o modelo HW-NARX atingiu um valor em torno de 0,5888, enquanto o modelo NARX alcançou um número menor em relação ao modelo proposto com um erro perto de 0,5660. O HW foi o que atingiu maiores erros e consequentemente o pior desempenho, com uma taxa de erro aproximada de 0,7486.

O algoritmo híbrido proposto HW-NARX obteve um erro MAPE próximo a 6,6991, por outro lado o NARX alcançou uma taxa menor de erro, com um valor de 6,4116, sendo a menor taxa de erro entre os algoritmos comparados. Para o HW o erro ficou próximo de 8,0772, sendo o maior para o MAPE dentre os modelos testados.

Logo a melhor performance entre os algoritmos HW, NARX e o HW-NARX para o horizonte de 1 hora 30 passos à frente, foi o NARX com menores taxas de erro em todos os erros usados (MSE, RMSE e MAPE) como parâmetros para identificar o melhor desempenho.

Gráfico 4.17 - Comparativo de erros (Horizonte de 1 hora 30 passos à frente).

Horizonte de 1 Hora 30 passos à frente



Fonte: AUTOR (2021).

A análise do comportamento das linhas de previsões é possível a partir da observação do Gráfico 4.18, onde encontra-se o comportamento das previsões da velocidade do vento dos

algoritmos HW, NARX e do modelo proposto HW-NARX para o horizonte de tempo de 1 hora 30 passos à frente.


Os comportamentos das linhas de previsões estão próximos da velocidade original, no qual o HW é o que menos se aproxima ao longo do tempo, isto pode ser comprovado não só na observação das linhas de previsão do Gráfico 18 como também nos erros dos algoritmos observados no Gráfico 4.17.

O modelo híbrido proposto teve um comportamento da linha de previsão melhor que o HW, mas em contrapartida obteve resultados piores em relação ao modelo NARX. O HW-NARX tem uma oscilação no comportamento da amplitude em relação à velocidade original, não a imitando de forma espelhada.

O NARX foi o modelo que atingiu os melhores resultados de previsão para o horizonte de 1 hora 30 passos à frente, onde imita de forma mais idêntica que os outros algoritmos a forma como a velocidade original se comporta ao longo das horas, sendo que a amplitude da linha de previsão do NARX segue ao longo das 30 horas a velocidade original.

Assim, o melhor comportamento da linha de previsão entre os algoritmos HW, NARX e HW-NARX tendo em vista o horizonte de 1 hora 30 passos à frente, foi o NARX.

Gráfico 4.18 - Comparativo de previsão (Horizonte de 1 hora 30 passos à frente).



Fonte: AUTOR (2021).

O algoritmo que conseguiu se sobressair na performance para o horizonte de 1 hora foi o modelo HW, pois foi melhor em dois (horizonte de 1 hora 5 e 10 passos à frente) dos três

cenários analisados, sendo que no terceiro cenário que teve como vencedor o NARX (horizonte de 1 hora 30 passos à frente) o NARX não teve uma superioridade maior que o HW teve no cenário 2 (horizonte de 1 hora 10 passos à frente) para o segundo colocado que foi o próprio NARX.

O modelo proposto não foi melhor em nenhum dos cenários analisados para este horizonte de tempo.

4.3.1.3 Horizonte de 1 Dia

O Gráfico 4.19 apresenta os erros MSE, RMSE e MAPE dos algoritmos de previsão utilizados neste trabalho para prever a velocidade do vento em PTR, algoritmos nomeados de HW, NARX e o modelo proposto HW-NARX, o gráfico é baseado no horizonte de 1 dia 5 passos à frente, que tem como finalidade evidenciar a performance de previsão dos algoritmos, encontrando o melhor modelo para este cenário.

O modelo HW-NARX alcançou o menor erro MSE com um valor aproximado de 0,2195, sendo a melhor performance entre os algoritmos testados para o erro MSE. O modelo NARX atingiu uma taxa de erro próxima de 0,2845 para o erro MSE, porém não foi o que alcançou o maior erro MSE entre os algoritmos, pois o HW conseguiu superar o NARX com um erro maior de aproximadamente 1,7290.


Na comparação do erro RMSE entre os modelos, o HW-NARX chegou a um erro aproximado de 0,4685, atingindo o menor erro RMSE entre os algoritmos analisados. O modelo NARX assim como no erro MSE foi o segundo colocado em termos de performance, com um erro em torno de 0,5334. O pior desempenho tendo como parâmetro o erro RMSE, foi o HW com uma taxa maior que os seus concorrentes chegando perto de 1,3149 de erro.

Levando em consideração apenas o erro MAPE, a performance manteve-se a mesma para os algoritmos, sendo o modelo proposto conseguido a melhor performance com uma taxa de erro em torno de 4,4216, já o modelo NARX alcançou a segunda colocação com um erro MAPE arredondado de 5,1929. O pior desempenho foi o do HW que atingiu um erro MAPE aproximado de 15,8442.

A melhor performance entre os modelos analisados foi o modelo proposto que teve menores erros no MSE, RMSE e MAPE, configurando-se assim o melhor modelo para a previsão da velocidade do vento do presente cenário apresentado no Gráfico 4.19.

Gráfico 4.19 - Comparativo de erros (Horizonte de 1 dia 5 passos à frente).

Horizonte de 1 Dia 5 passos à frente




Fonte: AUTOR (2021).

O Gráfico 4.20 apresenta o comportamento das previsões realizadas pelos algoritmos de previsões sazonais HW, NARX e o modelo híbrido proposto neste trabalho HW-NARX, que neste cenário (horizonte de 1 dia 5 passos à frente) são comparados com a velocidade do vento original.

No Gráfico 4.20 é possível notar que o pior modelo para este cenário foi o HW, que seguiu uma linha quase retilínea ao longo do tempo, não se comportando como a velocidade original do vento, que tem no intervalo do primeiro dia ao segundo, uma crescente da velocidade do vento que nos intervalos do dia 2 ao dia 4 há uma diminuição gradativa da velocidade do vento, mantendo quase a mesma velocidade no quarto e no quinto dia analisados.

Já o modelo proposto e o NARX têm o mesmo comportamento ao longo do tempo, com uma pequena variação na velocidade do vento entre ambos, sendo que o modelo proposto HW-NARX teve um melhor desempenho na linha de previsão, pois os valores estão mais próximos da velocidade original. Como a linha de previsão do modelo proposto está quase sobrepondo a linha do NARX ao analisar o Gráfico 4.20, pode-se observar o Gráfico 4.19 para averiguar que o modelo proposto realmente está tendo um erro menor e assim consequentemente tendo uma melhor previsão.

Gráfico 4.20 - Comparativo de previsão (Horizonte de 1 dia 5 passos à frente).



Fonte: AUTOR (2021).

O Gráfico 4.21 apresenta os erros MSE, RMSE e MAPE dos modelos HW, NARX e o modelo proposto HW-NARX para o presente cenário de horizonte de 1 dia 10 passos à frente.

Para o erro MSE o modelo proposto HW-NARX obteve um erro aproximado de 0,3833, ao qual deixou-o em segundo lugar em termos de desempenho levando em consideração apenas o MSE. O NARX teve um erro MSE menor que o modelo proposto, sendo o algoritmo entre os três analisados com o menor erro e conseqüentemente o melhor desempenho para o erro MSE especificamente, com um valor de aproximadamente de 0,3523. Enquanto que o HW não teve bons resultados se comparados com o NARX e o HW-NARX, pois teve um erro MSE maior chegando próximo de 4,2792, sendo classificado o algoritmo menos eficiente considerando apenas o erro MSE.

Em relação ao erro RMSE o modelo proposto atingiu um erro aproximado de 0,6191, sendo o segundo melhor modelo na classificação de desempenho para o erro RMSE. O NARX conseguiu mais uma vez superar o modelo proposto, desta vez alcançando um erro RMSE menor com um valor em torno de 0,5935, conforme pode ser visto no Gráfico 4.21. O HW ficou com um RMSE além dos concorrentes, sendo mais uma vez o menos eficiente com uma taxa de erro de 2,0686.


Levando em consideração apenas o erro MAPE os resultados seguem a mesma tendência dos erros MSE e RMSE conforme pode ser observado no Gráfico 4.21, onde o

modelo proposto conseguiu o segundo melhor desempenho com um valor de erro próximo a 6,9811, enquanto que o modelo NARX mais uma vez superou o modelo proposto, como um erro menor de 6,8869, sendo assim o modelo mais eficiente na comparação do parâmetro de erro MAPE. O HW não teve bons resultados neste cenário, alcançando um valor relativamente alto em comparação a seus concorrentes, com um erro MAPE em torno de 25,7686.

O modelo NARX foi o destaque deste cenário de previsão de horizonte de 1 dia 10 passos à frente, tendo alcançado erros menores no MSE, RMSE e MAPE, logo foi o modelo que apresentou a melhor performance e a maior eficácia na previsão da velocidade do vento. O destaque negativo para este cenário analisado é voltado ao algoritmo HW, que em contrapartida ao modelo NARX teve os maiores erros no MSE, RMSE e MAPE, sendo o algoritmo com menos eficiência na previsão da velocidade do vento.

Gráfico 4.21 - Comparativo de erros (Horizonte de 1 dia 10 passos à frente).

Horizonte de 1 Dia 10 passos à frente



Fonte: AUTOR (2021).


No Gráfico 4.22 é apresentado o comportamento das linhas de previsões dos algoritmos HW, NARX e o modelo proposto HW-NARX para o horizonte de tempo de 1 dia 10 passos à frente, tendo como parâmetro de comparação a velocidade original do vento.

Ao observar o Gráfico 4.22 pode-se notar que o modelo HW foi o pior em performance e comportamento da linha de previsão, que se comportou com de forma quase linear em uma velocidade de aproximadamente 5,6 m/s, sem o mínimo de variância na amplitude de sazonalidade se comparado com a velocidade original do vento. Logo foi o algoritmo de previsão com o pior desempenho de previsão.

O modelo NARX e o modelo proposto tiveram um comportamento muito próximo um ao outro, que fica muito difícil identificar qual dos dois teve o melhor desempenho, neste caso pode-se observar o Gráfico 4.21 onde estão os erros de cada algoritmo, nele pode-se notar que o modelo NARX foi o que adquiriu uma melhor performance e que conseqüentemente tem uma linha de previsão melhor, apresentando uma menor taxa de erro. A visualização desta diferença é difícil de notar no Gráfico 4.22, pois a diferença está em uma escala muito baixa.

Por uma pequena diferença de erro, o NARX teve a melhor performance, sendo que apenas o NARX e o modelo proposto conseguiram se aproximar da velocidade do vento original, espelhando mesmo que de forma leve o comportamento da linha alvo (velocidade original).

Gráfico 4.22 - Comparativo de previsão (Horizonte de 1 dia 10 passos à frente).



Fonte: AUTOR (2021).

No Gráfico 4.23 é apresentado um comparativo de performance no qual é utilizado como parâmetros os erros MSE, RMSE e MAPE, com a finalidade de evidenciar o algoritmo mais eficiente para a previsão da velocidade no horizonte de tempo de 1 dia 30 passos à frente, os algoritmos utilizados na comparação são os algoritmos de previsão de séries temporais HW, NARX e o modelo híbrido proposto neste trabalho o HW-NARX.

Na comparação dos modelos em relação ao erro MSE, o modelo proposto teve o segundo menor erro, com um valor aproximado de 0,7081. A rede neural NARX atingiu um valor ainda menor e conseqüentemente uma maior eficiência na previsão, a taxa de erro ficou

em torno de 0,6213, enquanto que o HW teve o pior desempenho com um erro aproximado de 1,5974, mais que o dobro do segundo colocado (HW-NARX).


Em relação ao RMSE o modelo proposto alcançou uma taxa de erro de aproximadamente 0,8415, sendo o algoritmo com o segundo menor erro. O modelo NARX mais uma vez foi o que obteve a melhor performance, atingindo um erro menor que o do modelo proposto, ficando próximo de 0,7882, enquanto que o HW foi o que apresentou a menor eficiência, atingindo o maior erro RMSE entre os algoritmos analisados, alcançando uma taxa de erro próxima a 1,2639.

Para o erro MAPE o que apresentou os melhores resultados foi a rede neural recorrente NARX, com uma taxa de erro ficando próxima de 9,3501, logo foi o modelo que teve o melhor desempenho de previsão. O modelo proposto ficou em segundo lugar na classificação de melhor performance, no qual atingiu um erro MAPE de aproximadamente 9,9007. O HW foi o menos eficiente na previsão e obteve uma taxa de erro MAPE próxima de 14,4899.

Após análise feita deste cenário a rede neural NARX foi a que conseguiu os melhores resultados de performance, tendo alcançado os menores erros no MSE, RMSE e MAPE. O destaque negativo é destinado ao HW, em que foi o menos eficiente entre os modelos comparados e com valores de erros significativamente maiores em relação aos concorrentes.

Gráfico 4.23 - Comparativo de erros (Horizonte de 1 dia 30 passos à frente).

Horizonte de 1 Dia 30 passos à frente



Fonte: AUTOR (2021).


No Gráfico 4.24 é mostrado o comportamento das linhas de previsões dos algoritmos HW, NARX e o modelo proposto HW-NARX, levando em consideração o cenário apresentado

no horizonte de 1 dia 30 passos à frente. Para a comparação dos algoritmos é utilizado o valor da velocidade original como parâmetro de confiabilidade da previsão.

O modelo HW foi o que apresentou uma menor eficiência na previsão, no Gráfico 4.24 é possível notar que apesar do HW ter espelhado o comportamento da velocidade original, ou seja, conseguiu identificar a sazonalidade, a amplitude da linha de previsão não seguiu o mesmo comportamento a partir do ponto 16 (décimo sexto dia de previsão), onde perdeu o espelhamento da velocidade original e não conseguiu fazer uma previsão com uma maior acuracidade.

Em relação ao modelo NARX, o comportamento foi muito semelhante ao do modelo proposto HW-NARX, conseguindo espelhar o comportamento da velocidade original, com uma amplitude sendo menor que a da velocidade original, mas mantendo o mesmo range de velocidade do vento no eixo y (velocidade do vento m/s). Logo, o melhor comportamento de linha de previsão foi o do modelo NARX, que atingiu menores erros que o modelo proposto, isso pode ser visto no Gráfico 4.23.

Gráfico 4.24 - Comparativo de previsão (Horizonte de 1 dia 30 passos à frente).



Fonte: AUTOR (2021).

Com a análise feita do horizonte de 1 dia, chega-se ao resultado de que o melhor algoritmo de previsão analisado para este cenário foi o NARX, que obteve uma maior eficiência nos horizontes de 1 dia 10 e 30 passos à frente, enquanto que o modelo proposto foi melhor apenas no horizonte de 1 dia 5 passos à frente.

O HW foi o que teve a pior performance, além de não obter uma performance maior em nenhum dos cenários, também foi o pior em todos os cenários testados para o horizonte de 1 dia.

4.3.1.4 Horizonte de 1 Semana

O Gráfico 4.25 exibe um comparativo entre os modelos de previsão HW, NARX e o modelo híbrido proposto HW-NARX, que tem como parâmetros de comparação os erros MSE, RMSE e o MAPE, a análise é feita para o horizonte de 1 semana 5 passos à frente.

Observando o Gráfico 4.25 é possível notar que em relação ao erro MSE o algoritmo proposto foi o mais eficiente na previsão da velocidade do vento para este cenário, é possível aferir isto devido ao erro MSE atingindo pelo HW-NARX ter um valor aproximado de 0,4400, que foi menor que os concorrentes, configurando-o como o modelo com maior desempenho e maior previsibilidade da velocidade do vento para cenário analisado. Ainda em relação ao erro MSE, o NARX obteve um valor aproximado de 0,5842, sendo classificado como o segundo algoritmo com melhor eficiência na previsibilidade da velocidade do vento, se comparado aos modelos HW e HW-NARX. O pior desempenho fica por conta do modelo HW, que atingiu uma taxa de erro próxima de 1,5884, sendo mais que o triplo de erro alcançado pelo modelo proposto HW-NARX.


No comparativo dos modelos tendo como parâmetro o erro RMSE, o modelo proposto continua se mostrando mais eficiente, tendo alcançado um erro aproximado de 0,6634, enquanto que o modelo de rede neural recorrente NARX alcançou uma taxa de 0,7643, sendo o segundo algoritmo com maior eficiência. O modelo HW teve a maior taxa de erro RMSE entre os modelos comparados, sendo o valor chegando próximo de 1,2603, conforme pode ser visualizado no Gráfico 4.25.

Tendo o erro MAPE como parâmetro de comparação e avaliação de performance, o modelo proposto foi o melhor entre os três algoritmos testados, alcançando um erro MAPE menor que os demais, com um valor em torno de 6,5773. Já o modelo NARX alcançou um erro com um valor próximo a 8,1978, sendo assim o segundo algoritmo com melhor eficiência na previsão da velocidade do vento para o cenário analisado. Enquanto que o HW atingiu um erro MAPE alto em comparação aos demais, com um valor maior que o dobro do erro MAPE do modelo proposto HW-NARX, tendo alcançado um erro próximo a 14,4629.

Pela análise feita deste cenário exposto no Gráfico 4.25, o modelo proposto alcançou menores erros nos parâmetros MSE, RMSE e MAPE, podendo ser assim classificado como o melhor modelo para previsão da velocidade do vento para o cenário de horizonte de 1 semana 5 passos à frente. Destaque negativo para o modelo HW, que teve maiores erros em todos os parâmetros analisados (MSE, RMSE e MAPE).

Gráfico 4.25 - Comparativo de erros (Horizonte de 1 semana 5 passos à frente).

Horizonte de 1 Semana 5 passos à frente




Fonte: AUTOR (2021).

No Gráfico 4.26 é apresentado o comportamento das linhas de previsões dos modelos de previsão de séries temporais com sazonalidade HW, NARX e o modelo híbrido proposto neste trabalho HW-NARX, que conforme pode ser observado no gráfico tais linhas de previsões são comparadas com a velocidade do vento original.

O modelo HW teve o pior comportamento de previsão, com uma previsão ao longo do tempo linear, sem alterações na amplitude no eixo y (velocidade do vento m/s). Já o modelo NARX teve um comportamento mais próximo da velocidade original, apesar de não ter tido o mesmo comportamento. O modelo NARX teve um comportamento muito parecido com o modelo proposto, sendo difícil identificar pelo Gráfico 4.26, assim pode-se recorrer ao Gráfico 4.25 em que os erros mostram que o modelo proposto tem uma previsibilidade maior que o modelo NARX, tendo em vista que obteve menores erros.

Gráfico 4.26 - Comparativo de previsão (Horizonte de 1 semana 5 passos à frente).



Fonte: AUTOR (2021).

No Gráfico 4.27 é mostrado o comparativo dos algoritmos de previsão utilizados para a previsão da velocidade do vento, ao qual é utilizado a base de dados de PTR, os algoritmos comparados são o HW, NARX e o modelo proposto HW-NARX, como parâmetro de comparação é utilizado os erros MSE, RMSE e MAPE, como forma de identificar o modelo com melhor eficiência e previsibilidade no cenário exposto no Gráfico 4.27.

Levando em consideração apenas o erro MSE, o modelo proposto foi o que apresentou melhores resultados de performance, já que o mesmo atingiu um erro menor que os demais algoritmos comparados, com um valor aproximado de 0,6537. O modelo NARX ficou em segundo lugar com uma taxa de erro em torno de 0,7027, o que não foi uma diferença alta do modelo proposto. Enquanto que o algoritmo que obteve o pior desempenho foi o HW, que atingiu um erro MSE de aproximadamente 2,6900.


Em relação ao erro RMSE, o modelo proposto também foi o que apresentou uma melhor performance com um erro menor que os demais algoritmos testados, com um valor de erro RMSE em torno de 0,8085. O algoritmo que ficou em segundo lugar em questão de desempenho foi a rede neural recorrente NARX, que alcançou um erro de 0,8383, um valor próximo ao do modelo proposto. O pior desempenho fica por parte do HW, que mais uma vez foi o que apresentou maiores erros em relação aos demais algoritmos concorrentes.

Para o parâmetro de comparação MAPE, o modelo proposto atingiu novamente o melhor desempenho com um menor erro, erro este que foi próximo de 7,2974, enquanto que o modelo NARX ficou com um erro em torno de 7,6846, configurando-se como a segunda melhor performance entre os algoritmos testados, já que o HW teve um erro muito maior que o NARX, com uma taxa de erro aproximada de 17,6408, conforme pode ser observado no Gráfico 4.27.

Fazendo uma análise deste cenário (horizonte de 1 semana 10 passos à frente), o modelo proposto foi o vencedor com a melhor performance, ganhado dos algoritmos HW e NARX em todos os erros utilizados como forma de comparação (MSE, RMSE e MAPE). Em contrapartida o modelo teve menos eficiência na previsibilidade da velocidade do vento para o cenário analisado foi o HW, tendo a pior performance em todos os parâmetros analisados (MSE, RMSE e MAPE).

Gráfico 4.27 - Comparativo de erros (Horizonte de 1 semana 10 passos à frente).

Horizonte de 1 Semana 10 passos à frente




Fonte: AUTOR (2021).

No Gráfico 4.28 é apresentado as linhas de previsões realizadas pelos algoritmos HW, NARX e o modelo proposto HW-NARX, que como parâmetro de comparação foi utilizado os dados da velocidade original. A comparação de linhas de previsão dos modelos é realizada com base no horizonte de tempo de 1 semana 10 passos à frente. É válido ressaltar que o horizonte de semanas está na unidade de medida em semana (cada ponto no eixo x representa uma semana).

O modelo HW apresentou resultados insatisfatórios em relação aos modelos NARX e o HW-NARX, pois a sua linha de previsão se comportou de forma quase que linear durante as 10 semanas analisadas neste cenário. Logo foi o algoritmo que teve menos eficiência na previsibilidade da velocidade do vento.

O modelo NARX teve um comportamento da linha de previsão semelhante a linha de previsão do modelo proposto, no qual é difícil analisar pelo Gráfico 4.28 a diferença entre ambos e aferir qual foi o melhor, no entanto no Gráfico 4.27 é possível verificar que o modelo proposto teve menores erros e consequentemente tem uma melhor linha de previsão que o NARX. Vale ressaltar que o modelo proposto e o modelo NARX tiveram um comportamento de linha de previsão aproximados da velocidade original.

Gráfico 4.28 - Comparativo de previsão (Horizonte de 1 semana 10 passos à frente).



Fonte: AUTOR (2021).

O Gráfico 4.29 apresenta um comparativo de desempenho entre os algoritmos HW, NARX e o modelo híbrido proposto HW-NARX, no qual são utilizados os erros MSE, RMSE e MAPE para comparar a performance de tais algoritmos. O horizonte de tempo utilizado neste cenário de testes é o horizonte de 1 semana 30 passos à frente, conforme pode ser observado no Gráfico 4.29.

Para o parâmetro de performance MSE, o modelo proposto alcançou o melhor resultado e consequentemente o menor erro, com um valor aproximado de 0,3886, enquanto que para este mesmo erro o NARX atingiu um valor próximo de 0,4246, sendo o segundo melhor resultado

alcançado para este cenário e parâmetro MSE. Por outro lado, o HW teve um resultado ruim, com um erro muito discrepante em relação aos demais, com um valor em torno de 11 vezes mais que o resultado do segundo colocado (NARX), tendo um valor de 4,9648 de erro RMSE.


Levando em consideração o parâmetro RMSE, o modelo proposto HW-NARX alcançou o melhor resultado novamente, com uma taxa de erro aproximada de 0,6234, o modelo NARX alcançou o segundo melhor resultado com um valor de erro RMSE de quase 0,6516. Novamente o algoritmo que apresentou o resultado com maior erro foi HW, que atingiu um erro com valor perto de 2,2282.

Na comparação entre os algoritmos para o parâmetro de erro MAPE, o modelo proposto teve um resultado muito próximo do NARX, porém a taxa de erro ainda é menor, sendo assim o modelo proposto foi o algoritmo com melhor performance se comparado o erro MAPE entre os algoritmos, com um valor aproximado de 5,4710. O NARX alcançou o segundo menor erro como resultado do MAPE entre os algoritmos, com um valor em torno de 5,6512. O HW teve como resultado um valor discrepante dos outros dois modelos, com um valor aproximado de 21,0782, sendo o pior em performance para este cenário analisado tendo como base o MAPE.

O modelo que teve os melhores resultados de performance foi o modelo proposto HW-NARX que alcançou erros menores em todos os parâmetros analisados (MSE, RMSE e MAPE) do cenário apresentado no Gráfico 4.29.

Gráfico 4.29 - Comparativo de erros (Horizonte de 1 semana 30 passos à frente).

Horizonte de 1 Semana 30 passos à frente




Fonte: AUTOR (2021).

O Gráfico 4.30 mostra o comportamento das linhas de previsões da velocidade do vento resultantes do teste realizado utilizando os algoritmos HW, NARX e o modelo híbrido proposto HW-NARX, no qual a linhas de previsões são comparadas com a velocidade original do vento que serve como base de comparação e confiabilidade da previsibilidade dos modelos. O cenário analisado é o horizonte de 1 semana a 30 passos à frente.

O comportamento da linha de previsão do modelo HW não foi satisfatório, pois não possui um comportamento minimamente parecido com o da velocidade original, saindo de da velocidade de 8 m/s e indo a aproximadamente 7 m/s ao longo do tempo, diminuindo a velocidade do vento quase que gradativamente.

O modelo NARX teve um comportamento parecido com o comportamento da velocidade original, e muito semelhante ao do modelo proposto, no qual o modelo NARX teve uma boa previsibilidade, e mais uma vez é complicado afirmar algo sobre qual modelo teve a melhor previsibilidade, porém quando se recorre ao Gráfico 4.29 fica nítido que o modelo proposto foi o que teve a melhor performance, devido aos erros serem menores. A previsibilidade depende dos erros analisados, os gráficos de linhas de previsão servem para serem analisados os comportamentos dos valores previstos com os valores reais.

Gráfico 4.30 - Comparativo de previsão (Horizonte de 1 semana 30 passos à frente).



Fonte: AUTOR (2021).

Após ser analisado o cenário composto pelo horizonte de 1 semana, tem-se que o algoritmo que alcançou os melhores resultados de performance e previsibilidade foi o modelo

híbrido proposto, tendo uma performance melhor que o HW e NARX em todos os cenários do horizonte de 1 semana (médio prazo).

O destaque negativo foi o HW que foi o menos eficiente em performance e consequentemente em previsibilidade em todos os cenários do horizonte de 1 semana.

Como resultado final tem-se o Quadro 4.2, que reúne os principais resultados obtidos, indicando que o algoritmo proposto teve os melhores resultados para o horizonte de 10 minutos (ultracurto prazo) e para o horizonte de 1 semana (médio prazo e longo prazo).

Quadro 4.2 - Melhor algoritmo entre os horizontes analisados.

Horizonte	Passos à Frente	Melhor Performance de Previsão
10 Minutos	5	<i>HW-NARX</i>
10 Minutos	10	<i>HW-NARX</i>
10 Minutos	30	<i>HW-NARX</i>
1 Hora	5	HW
1 Hora	10	HW
1 Hora	30	NARX
1 Dia	5	<i>HW-NARX</i>
1 Dia	10	NARX
1 Dia	30	NARX
1 Semana	5	<i>HW-NARX</i>
1 Semana	10	<i>HW-NARX</i>
1 Semana	30	<i>HW-NARX</i>

Fonte: AUTOR (2021).

Com os resultados alcançados, é possível aferir que o modelo proposto pode ser utilizado para a previsão da velocidade do vento em diferentes horizontes de tempo, como ultracurto prazo, médio prazo e longo prazo, que segundo Zhao, Wang e Li (2011), tais previsões são benéficas para a geração de energia eólica:

Ultracurto prazo:

- Ações de regulação do controle de turbina eólica;
- Compensação do mercado de eletricidade.

Médio prazo:

- Gerador de Decisões Online/Offline (Providências para manutenção);
- Decisões de Compromisso da Unidade.

Longo prazo:

- Programação de manutenção para obter o custo operacional ideal;
- O Estudo de Viabilidade para Projeto do Parque Eólico.

No Quadro 4.3 é realizado um comparativo de trabalhos relacionados de algoritmos híbridos para a previsão da velocidade do vento.

Quadro 4.3 - Comparativo de trabalhos relacionados (Algoritmos Híbridos).

Autores	Modelos	Horizontes de tempo			
		Ultracurto prazo	Curto prazo	Médio prazo	Longo prazo
(ALY, 2020)	<i>Wavelet</i> , RNA, Séries Temporais com FKR	Não	Não	<i>Sim</i>	<i>Sim</i>
(FEITOSA, HÄRTER e CALVETTI, 2019)	Previsão por conjuntos e cálculo variacional quadridimensional (En4DVAR) e <i>Weather Research and Forecasting Model</i> (WRF)	Não	<i>Sim</i>	Não	Não
(JÚNIOR, PESSANHA e SOUZA, 2011)	Decomposição de <i>Wavelet</i> com RNA	<i>Sim</i>	Não	Não	Não
(CHANG <i>et al.</i> , 2017)	Rede Neural de Função de Base Radial com um esquema de Feedback de Erro do inglês (Improved Radial Basis Function Neural Network with an Error Feedback - IRBFNN-EF)	Não	<i>Sim</i>	Não	Não
(ZHU <i>et al.</i> , 2019)	Hybrid Model of TDRG (Top-Down Relevant Feature Search), GPR (Gaussian Process Regression) and LSTM	<i>Sim</i>	Não	Não	Não
(CAMELO <i>et al.</i> , 2017)	ARIMA com RNA	Não	Não	Não	<i>Sim</i>
(CAMELO <i>et al.</i> , 2017)	HW com RNA	Não	Não	Não	<i>Sim</i>
Autor deste trabalho (Parente)	Modelo Proposto (HW com NARX)	<i>Sim</i>	Não	<i>Sim</i>	<i>Sim</i>

Fonte: AUTOR (2021).

No Quadro 4.3 pode-se observar que o modelo proposto tem uma característica que não é comum nos algoritmos de previsão utilizados para a previsão da velocidade do vento, que é a possibilidade de ter previsões com menos erros e maior confiabilidade (próximo de 100%) para diferentes horizontes de tempo, geralmente os algoritmos são bons para a previsão de um ou dois horizontes de tempo, enquanto que o modelo híbrido proposto HW-NARX (tendo em vista os testes realizados) se saiu bem para três horizontes, ultracurto, médio e longo prazo.

CAPÍTULO 5

5 CONCLUSÕES E SUGESTÕES

5.1 CONCLUSÕES

O trabalho produzido alcançou os objetivos estabelecidos, no qual foi elaborado e apresentado uma revisão dos modelos de previsão de séries temporais ARIMA, SARIMA, HW, RNA e NARX, mostrando o funcionamento de cada algoritmo e seus benefícios.

Na escolha da base de dados foram selecionadas duas bases de dados (BRB e PTR), no qual a de BRB foi utilizada para encontrar o melhor algoritmo de treinamento, já a base de PTR foi utilizada para realizar os testes no modelo híbrido proposto HW-NARX, HW e NARX, já que a velocidade média do vento é mais alta e possui menos inconsistências que a base de BRB.

Após ter definido as bases de dados a serem utilizadas, a etapa seguinte se baseou em utilizar a base de BRB para encontrar a melhor configuração da rede neural NARX, tendo como resultado o BS como o algoritmo de treinamento que obteve as melhores performances diante dos cenários analisados.

Com a configuração do melhor modelo para a rede NARX definida, foi utilizado a base de dados de PTR para realizar os testes nos modelos HW, NARX e no modelo proposto HW-NARX. Nos testes de comparação entre os algoritmos, o modelo proposto alcançou menores erros e melhores performances de previsibilidade no horizonte de 10 minutos 5, 10 e 30 passos à frente, além de ter atingido melhores performances no horizonte de 1 semana 5, 10 e 30 passos à frente.

A melhor performance do algoritmo proposto em comparação ao HW e NARX entre todos os cenários apresentados foi o do horizonte de 10 minutos 5 passos à frente, no qual o modelo proposto HW-NARX atingiu uma taxa de erro MAPE aproximada de 10,8202 e o NARX teve um valor aproximado de 18,6252, enquanto que o HW atingiu um valor para o erro MAPE de 16,5907.

Com os resultados obtidos pode-se concluir que o algoritmo proposto pode ser utilizado para a previsão da velocidade do vento na geração de energia eólica em diferentes horizontes de previsão, como ultracurto prazo, médio prazo e a longo prazo.

5.2 SUGESTÕES PARA TRABALHOS FUTUROS

O tema abordado neste trabalho é amplo e pode ter diversas aplicações, assim para trabalhos futuros sugestionam-se alguns itens que podem ser realizados, onde podem ser listados da seguinte forma:

- Utilizar o modelo proposto para realizar a previsão da velocidade do vento com outras bases, fazendo comparações com algoritmos híbridos encontrados na literatura.
- Aplicar o modelo proposto para a previsão de séries temporais com sazonalidade de diferentes ramos, como a previsão de variação de nível do rio.
- Utilizar algoritmos de treinamento bio-inspirados no modelo proposto HW-NARX, a fim de melhorar a convergência da rede neural.

REFERÊNCIAS

- AGUILAR-LOBO, Lina M. *et al.* Application of the NARX neural network as a digital predistortion technique for linearizing microwave power amplifiers. **Microwave and Optical Technology Letters**, v. 57, n. 9, p. 2137-2142, 2015.
- AHMED, Adil; KHALID, Muhammad. Multi-step ahead wind forecasting using nonlinear autoregressive neural networks. **Energy Procedia**, v. 134, p. 192-204, 2017.
- ALENCAR, David B. *et al.* Hybrid approach combining SARIMA and neural networks for multi-step ahead wind speed forecasting in Brazil. **IEEE Access**, v. 6, p. 55986-55994, 2018.
- ALTAN, Aytaç; KARASU, Seçkin; ZIO, Enrico. A new hybrid model for wind speed forecasting combining long short-term memory neural network, decomposition methods and grey wolf optimizer. **Applied Soft Computing**, v. 100, p. 106996, 2021.
- ALY, Hamed HH. An intelligent hybrid model of neuro Wavelet, time series and Recurrent Kalman Filter for wind speed forecasting. **Sustainable Energy Technologies and Assessments**, v. 41, p. 100802, 2020.
- ASHOOR, Asmaa Shaker; KAZEM, Ali Abdul Karim. A comparison between a network of predictive values of the Linear General Trend model and the Holt-Winter models in analyzing the annual production level of live meat chickens for the period from 2014-2019 in Iraq. **MJPS**, v. 8, n. 2, 2021.
- BABU, C. Narendra; REDDY, B. Eswara. A moving-average filter based hybrid ARIMA-ANN model for forecasting time series data. **Applied Soft Computing**, v. 23, p. 27-38, 2014.
- BANTUPALLI, Manoj Kumar; MATAM, Sailaja Kumari. Wind Speed forecasting using empirical mode decomposition with ANN and ARIMA models. In: **2017 14th IEEE India Council International Conference (INDICON)**. IEEE, 2017. p. 1-6.
- BARBOSA DE ALENCAR, David *et al.* Different models for forecasting wind power generation: Case study. **Energies**, v. 10, n. 12, p. 1976, 2017.

BARBOSA, André Luiz. Regulação para o armazenamento geológico de gás natural e energia no Brasil-Avaliação da situação atual, identificação de lacunas e recomendações. 2021. Dissertação de Mestrado. Universidade de Évora.

BARROS, Matheus Ferreira; OLIVEIRA, Fernando Luiz Cyrino; SOUZA, Reinaldo Castro. MODELOS DE SIMULAÇÃO DE CENÁRIOS DE PRODUÇÃO DE ENERGIA EÓLICA A PARTIR DO MÉTODO DE HOLT-WINTERS E SUAS VARIAÇÕES. 2015.

BARROS, Victor Pedroso Ambiel *et al.* **Avaliação do desempenho de algoritmos de retropropagação com redes neurais artificiais para a resolução de problemas não-lineares.** 2018. Dissertação de Mestrado. Universidade Tecnológica Federal do Paraná.

BHARDWAJ, Saurabh *et al.* Estimation of solar radiation using a combination of Hidden Markov Model and generalized Fuzzy model. **Solar Energy**, v. 93, p. 43-54, 2013.

BLÁZQUEZ-GARCÍA, Ane *et al.* Short-term office building elevator energy consumption forecast using SARIMA. **Journal of Building Performance Simulation**, v. 13, n. 1, p. 69-78, 2020.

BOUERES, Sara Medeiros *et al.* Avaliação do impacto de modelos de erro de previsão eólica na reserva operacional. 2020.

BOX, George EP; JENKINS, Gwilym M. Time series analysis: Forecasting and control San Francisco. **Calif: Holden-Day**, 1976.

CAMELO, Henrique do Nascimento *et al.* 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**, v. 32, n. 4, p. 565-574, 2017.

CARPINTEIRO, Otávio AS *et al.* A neural model in anti-spam systems. In: **International Conference on Artificial Neural Networks**. Springer, Berlin, Heidelberg, 2006. p. 847-855.

CHANG, G. W. et al. An improved neural network-based approach for short-term wind speed and power forecast. **Renewable energy**, v. 105, p. 301-311, 2017.

CHEN, Jinbo; ENGEDA, Abraham. Standard module hydraulic technology: A novel geometrical design methodology and analysis for a low-head hydraulic turbine system, part II:

Turbine stator-blade and runner-blade geometry, and off-design considerations. **Energy**, v. 214, p. 118982, 2021.

CHEN, Xue-Jun *et al.* Multi-step wind speed forecast based on sample clustering and an optimized hybrid system. **Renewable Energy**, v. 165, p. 595-611, 2021.

CREPALDI, Juliano; AMOROSO, Marcelo Marcos; ANDO, O. H. Analysis of the Topologies of Power Filters Applied in Distributed Generation Units-Review. **IEEE Latin America Transactions**, v. 16, n. 7, p. 1892-1897, 2018.

DA FONTOURA, Fernando Batista Bandeira; RABUSKE, Rodrigo; FRIEDRICH, Laercio Rogério. Análise da viabilidade para implantação de energia fotovoltaica com utilização para sombreamento de estacionamento. **Estudos do CEPE**, p. 36-48, 2018.

DA SILVA PEREIRA, Donisete *et al.* Diversificação de fontes geradoras da matriz elétrica brasileira: uma revisão sistemática. **Meio Ambiente (Brasil)**, v. 3, n. 1, 2021.

DA SILVA, Marina Raisa Vilela *et al.* ENERGIA EÓLICA, SOLAR E DE BIOMASSA: USO, PERSPECTIVA E DESAFIOS. **Biodiversidade**, v. 19, n. 4, 2020.

DA SILVA, Sandra Sereide Ferreira; ALVES, Allan Carlos; RAMALHO, Ângela Maria Cavalcanti. ENERGIA EÓLICA E COMPLEMENTARIDADE ENERGÉTICA: ESTRATÉGIA E DESAFIO PARA O DESENVOLVIMENTO SUSTENTÁVEL NA REGIÃO NORDESTE DO BRASIL. **Qualitas Revista Eletrônica**, v. 19, n. 3, p. 53-72, 2020.

DADA, Emmanuel Gbenga *et al.* Predicting protein secondary structure based on ensemble Neural Network. **ITEGAM-JETIA**, v. 7, n. 27, p. 49-56, 2021.

DE ABREU MACHADO, Melissa Gurgel. Benefícios da Implementação de Energia Eólica no Estado do Ceará-Brasil. 2020.

DONG, Qingli; SUN, Yuhuan; LI, Peizhi. A novel forecasting model based on a hybrid processing strategy and an optimized local linear fuzzy neural network to make wind power forecasting: A case study of wind farms in China. **Renewable Energy**, v. 102, p. 241-257, 2017.

DOS SANTOS CARSTENS, Danielle Denes; DA CUNHA, Sieglinde Kindl. Challenges and opportunities for the growth of solar photovoltaic energy in Brazil. **Energy policy**, v. 125, p. 396-404, 2019.

DOS SANTOS, Deilson Martins; DA SILVA OLIVEIRA, Ezequiel. Investigação de redes neurais artificiais para predição da velocidade do vento. **Simpósio Brasileiro de Sistemas Elétricos-SBSE**, v. 1, n. 1, 2020.

DOS SANTOS, José Airton Azevedo; SPANCERSKI, Jandrei Sartori Spancerski. Aplicação de redes neurais recorrentes na previsão de geração eólica. **Revista Cereus**, v. 13, n. 1, p. 217-227, 2021.

DOS SANTOS, Rodrigo Miguel; DE SÁ RODRIGUES, Marilsa; CARNIELLO, Monica Franchi. ENERGIA E SUSTENTABILIDADE: PANORAMA DA MATRIZ ENERGÉTICA BRASILEIRA. **Scientia: Revista Científica Multidisciplinar**, v. 6, n. 1, p. 13-33, 2021.

DUAN, Jikai *et al.* Short-term wind speed forecasting using recurrent neural networks with error correction. **Energy**, v. 217, p. 119397, 2021.

EHLERS, Ricardo S. Análise de séries temporais. **Laboratório de Estatística e Geoinformação**. Universidade Federal do Paraná, v. 1, p. 1-118, 2007.

EISSA, Mohammed *et al.* Wind Power Prediction Using a Hybrid Approach with Correction Strategy Based on Risk Evaluation. **International Journal of Renewable Energy Research (IJRER)**, v. 7, n. 3, p. 1352-1362, 2017.

EMPRESA DE PESQUISA ENERGÉTICA - EPE. Balanço Energético Nacional 2019: Ano Base 2018. Rio de Janeiro, Brasil: EPE. 2019.

FANIBAND, Yunus Parvej; SHAAHID, S. M. Univariate Time Series Prediction of Wind speed with a case study of Yanbu, Saudi Arabia. **International Journal**, v. 10, n. 1, 2021.

FEITOSA, Otavio Medeiros; HÄRTER, Fabrício Pereira; CALVETTI, Leonardo. Avaliação do Método de Assimilação de Dados En4DVar Implementado no Modelo WRF. **Anuário do Instituto de Geociências**, v. 43, n. 2, p. 405-414, 2019.

FENG, Zhong-kai; NIU, Wen-jing. Hybrid artificial neural network and cooperation search algorithm for nonlinear river flow time series forecasting in humid and semi-humid regions. **Knowledge-Based Systems**, v. 211, p. 106580, 2021.

GARDNER JR, Everette S. Exponential smoothing: The state of the art—Part II. **International journal of forecasting**, v. 22, n. 4, p. 637-666, 2006.

GÉRON, Aurélien. *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow*. Alta Books, 2019.

GERTRUDES, Ricardo Filipe Dias. Impactos da Variabilidade do Vento na Integração de Energia Eólica no Sistema Elétrico Nacional. 2020. Tese de Doutorado. Universidade de Coimbra.

GOBBO, Emilia Ribeiro. Do petróleo à energia fotovoltaica: a inserção do brasil neste novo mercado. **Do petróleo à energia fotovoltaica: a inserção do Brasil neste novo mercado**, p. 1-388–416, 2018.

GOMES, P. Vilaça *et al.* Technical-economic analysis for the integration of PV systems in Brazil considering policy and regulatory issues. **Energy policy**, v. 115, p. 199-206, 2018.

GONÇALVES, Rodrigo Mikosz *et al.* Modelagem preditiva de linha de costa utilizando redes neurais artificiais. **Boletim de Ciências Geodésicas**, v. 16, n. 3, p. 420-444, 2010.

HENNINGSSEN, Arne; HENNINGSSEN, Geraldine; VAN DER WERF, Edwin. Capital-labour-energy substitution in a nested CES framework: A replication and update of Kemfert (1998). **Energy Economics**, v. 82, p. 16-25, 2019.

HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long short-term memory. **Neural computation**, v. 9, n. 8, p. 1735-1780, 1997.

HUSSIN, Nor Hafizah *et al.* Forecasting Wind Speed in Peninsular Malaysia: An Application of ARIMA and ARIMA-GARCH Models. **Pertanika Journal of Science & Technology**, v. 29, n. 1, 2021.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting: principles and practice**. OTexts, 2018.

IPAKCHI, Ali; ALBUYEH, Farrokh. Grid of the future. **IEEE power and energy magazine**, v. 7, n. 2, p. 52-62, 2009.

JALLAL, Mohammed Ali *et al.* A hybrid neuro-fuzzy inference system-based algorithm for time series forecasting applied to energy consumption prediction. **Applied Energy**, v. 268, p. 114977, 2020.

JÚNIOR, Luiz Albino Teixeira; PESSANHA, José Francisco Moreira; SOUZA, Reinaldo Castro. Análise Wavelet e Redes Neurais Artificiais na Previsão da Velocidade de Vento. In: **Simpósio Brasileiro de Pesquisa Operacional. SBPO**. 2011.

KALEKAR, Prajakta S. *et al.* Time series forecasting using holt-winters exponential smoothing. **Kanwal Rekhi school of information Technology**, v. 4329008, n. 13, p. 1-13, 2004.

KAUSHIKA, N. D.; TOMAR, R. K.; KAUSHIK, S. C. Artificial neural network model based on interrelationship of direct, diffuse and global solar radiations. **Solar Energy**, v. 103, p. 327-342, 2014.

KOÇAK, Yılmaz; ŞIRAY, Gülesen Üstündağ. New activation functions for single layer feedforward neural network. **Expert Systems with Applications**, v. 164, p. 113977, 2021.

KOYUNCU, Kaan *et al.* Forecasting COVID-19 impact on RWI/ISL container throughput index by using SARIMA models. **Maritime Policy & Management**, p. 1-13, 2021.

KUMAR, Th Shanta *et al.* Analysis and Prediction of Air Pollution in Assam Using ARIMA/SARIMA and Machine Learning. In: **Innovations in Sustainable Energy and Technology**. Springer, Singapore, 2021. p. 317-330.

LEI, Ma *et al.* A review on the forecasting of wind speed and generated power. **Renewable and Sustainable Energy Reviews**, v. 13, n. 4, p. 915-920, 2009.

LETCHER, Trevor M.; WILLIAMSON, Arthur. Forms and Measurement of Energy. 2004.

LIU, Hui *et al.* A new hybrid ensemble deep reinforcement learning model for wind speed short term forecasting. **Energy**, v. 202, p. 117794, 2020.

LIU, Hui; TIAN, Hong-qi; LI, Yan-fei. Comparison of two new ARIMA-ANN and ARIMA-Kalman hybrid methods for wind speed prediction. **Applied Energy**, v. 98, p. 415-424, 2012.

LUDERER, Gunnar *et al.* Environmental co-benefits and adverse side-effects of alternative power sector decarbonization strategies. **Nature communications**, v. 10, n. 1, p. 1-13, 2019.

MALIK, Hasmat; YADAV, Amit Kumar. A novel hybrid approach based on relief algorithm and fuzzy reinforcement learning approach for predicting wind speed. **Sustainable Energy Technologies and Assessments**, v. 43, p. 100920, 2021.

MATKOVSKYY, romano; BOURAOUI, Taoufik. Aplicação de redes neurais a índices compostos de séries temporais curtas: Evidência do modelo não linear autoregressivo com entradas exógenas (narx). **Journal of Quantitative Economics**, v. 17, n. 2, pág. 433-446, 2019.

MCCULLOCH, Warren S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115-133, 1943.

MILLER, Lee M.; KEITH, David W. Observation-based solar and wind power capacity factors and power densities. **Environmental Research Letters**, v. 13, n. 10, p. 104008, 2018.

MORETTIN, Pedro A.; TOLOI, Clélia MC. **Análise de séries temporais: modelos lineares univariados**. Editora Blucher, 2018.

NAVARRO, Maricar M.; NAVARRO, Bryan B. Optimal Short-Term Forecasting Using GA-Based Holt-Winters Method. In: **2019 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)**. IEEE, 2019. p. 681-685.

NURHAMIDAH, Nurhamidah; NUSYIRWAN, Nusyirwan; FAISOL, Ahmad. Forecasting Seasonal Time Series Data using The Holt-Winters Exponential Smoothing Method of Additive Models. **Jurnal Matematika Integratif**, v. 16, n. 2, p. 151-157, 2020.

PAIM, Maria-Augusta *et al.* Evaluating regulatory strategies for mitigating hydrological risk in Brazil through diversification of its electricity mix. **Energy Policy**, v. 128, p. 393-401, 2019.

PALMER-WILSON, Kevin *et al.* Impact of land requirements on electricity system decarbonisation pathways. **Energy policy**, v. 129, p. 193-205, 2019.

PASTOR, João Cesar Silva; DE ALMEIDA MACÊDO, Ana Vitória. PANORAMA ATUAL E PERSPECTIVAS FUTURAS DAS FONTES DE ENERGIA RENOVÁVEIS INTERMITENTES NO NORDESTE BRASILEIRO. In: **VII Congresso Brasileiro de Energia Solar-CBENS 2018**. 2020.

PATTANAYAK, Radha Mohan; BEHERA, Himansu Sekhar; PANIGRAHI, Sibarama. A novel hybrid differential evolution-PSNN for fuzzy time series forecasting. In: **Computational Intelligence in Data Mining**. Springer, Singapore, 2020. p. 675-687.

PONGDATU, G. A. N.; PUTRA, Y. H. Seasonal Time Series Forecasting using SARIMA and Holt Winter's Exponential Smoothing. In: **IOP Conference Series: Materials Science and Engineering**. IOP Publishing, 2018. p. 012153.

QIU, Hongfang *et al.* Forecasting the incidence of mumps in Chongqing based on a SARIMA model. **BMC Public Health**, v. 21, n. 1, p. 1-12, 2021.

RAY, Soumik *et al.* Time series SARIMA Modelling and forecasting of monthly rainfall and temperature in the south Asian countries. **Earth Systems and Environment**, p. 1-16, 2021.

REIS, Leonardo Pequeno *et al.* Prognose da distribuição diamétrica na Amazônia utilizando redes neurais artificiais e autômatos celulares. **Floresta**, v. 48, n. 1, p. 93-102, 2018.

RELLA, Ricardo. Energia fotovoltaica no brasil. **Revista de Iniciação Científica**, v. 15, n. 1, p. 28-38, 2017.

SANDHU, K. S. *et al.* A comparative study of ARIMA and RNN for short term wind speed forecasting. In: **2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT)**. IEEE, 2019. p. 1-7.

SANTANA, Lêda Valéria Ramos *et al.* Análise da regularidade da velocidade do vento no Nordeste do Brasil através da Sample Entropy. **Research, Society and Development**, v. 9, n. 7, p. e762974746-e762974746, 2020.

SANTOS AZA, Cindy Juliana; ECHEVERRY CORREDOR, Bryan Alexander. REVISIÓN TEÓRICA DEL PANORAMA ENERGÉTICO DE LAS FUENTES NO CONVENCIONALES DE ENERGÍA RENOVABLES EN EL DEPARTAMENTO DE

SANTANDER, CON ÉNFASIS EN APROVECHAMIENTO DE LA BIOMASA EN FUNCIÓN DE LA MATRIZ DE GENERACIÓN ELÉCTRICA DE COLOMBIA. 2021.

SILVA, Gustavo Rodrigues. **Características de Vento da Região Nordeste: análise, modelagem e aplicações para projetos de centrais eólicas**. 2003. Dissertação de Mestrado. Universidade Federal de Pernambuco.

SILVA, Pollyanna Kelly de Oliveira *et al.* Análise e previsão de curto prazo do vento através de modelagem estatística em áreas de potencial eólico no Nordeste do Brasil. 2017.

SINGH, Pavan Kumar; SINGH, Nitin; NEGI, Richa. Wind power forecasting using hybrid ARIMA-ANN technique. In: **Ambient communications and computer systems**. Springer, Singapore, 2019. p. 209-220.

SINGH, Pritpal. A novel hybrid time series forecasting model based on neutrosophic-PSO approach. **International Journal of Machine Learning and Cybernetics**, v. 11, n. 8, p. 1643-1658, 2020.

SINGH, S. N. *et al.* Repeated wavelet transform based ARIMA model for very short-term wind speed forecasting. **Renewable energy**, v. 136, p. 758-768, 2019.

SONDA, Sistema de Organização Nacional de Dados Ambientais, 2021. Acessado em: 10 de dezembro de 2020. Disponível em: <http://sonda.ccst.inpe.br/infos/validacao.html>.

SOUZA, Felipe Maraschin Pereira de *et al.* Aplicação de uma rede neural artificial NARX para obtenção do comportamento dinâmico de um atenuador de impacto de alumínio do tipo Honeycomb. 2019.

VENTURA, Luciana Maria Baptista *et al.* Forecast of daily PM 2.5 concentrations applying artificial neural networks and Holt–Winters models. **Air Quality, Atmosphere & Health**, v. 12, n. 3, p. 317-325, 2019.

WANG, Wen-chuan *et al.* Improving forecasting accuracy of annual runoff time series using ARIMA based on EEMD decomposition. **Water Resources Management**, v. 29, n. 8, p. 2655-2675, 2015.

WILMS, Henning *et al.* Exploiting spatio-temporal dependencies for RNN-based wind power forecasts. In: **2019 IEEE PES GTD Grand International Conference and Exposition Asia (GTD Asia)**. IEEE, 2019. p. 921-926.

WINTERS, Peter R. Forecasting sales by exponentially weighted moving averages. **Management science**, v. 6, n. 3, p. 324-342, 1960.

WUNSCH, Andreas; LIESCH, Tanja; BRODA, Stefan. Previsão dos níveis de água subterrânea usando redes autorregressivas não lineares com entrada exógena (NARX). **Journal of hydrology**, v. 567, p. 743-758, 2018.

XU, Feng *et al.* Prediction of fish migration caused by ocean warming based on SARIMA model. **Complexity**, v. 2021, 2021.

XU, Qiang *et al.* Ultra-short-term Wind Speed Forecast Based on WD-ARIMAX-GARCH Model. In: **2019 IEEE 2nd International Conference on Automation, Electronics and Electrical Engineering (AUTEEE)**. IEEE, 2019. p. 219-222.

YATIYANA, Eddie; RAJAKARUNA, Sumedha; GHOSH, Arindam. Wind speed and direction forecasting for wind power generation using ARIMA model. In: **2017 Australasian Universities Power Engineering Conference (AUPEC)**. IEEE, 2017. p. 1-6.

ZHANG, Jinliang; WEI, Yiming; TAN, Zhongfu. An adaptive hybrid model for short term wind speed forecasting. **Energy**, v. 190, p. 115615, 2020.

ZHAO, Xin; WANG, Shuangxin; LI, Tao. Review of evaluation criteria and main methods of wind power forecasting. **Energy Procedia**, v. 12, p. 761-769, 2011.

ZHU, Shuang *et al.* Gaussian mixture model coupled recurrent neural networks for wind speed interval forecast. **Energy Conversion and Management**, v. 198, p. 111772, 2019.

APÊNDICES


APÊNDICE A – ARTIGO PUBLICADO

O artigo fruto deste trabalho foi publicado no periódico *International Journal of Development Research* (2230-9926). O artigo é intitulado como “*Application of the narx model for forecasting wind speed for wind energy generation*”, publicado na edição de abril de 2021 (Vol. 11 Issue 4).

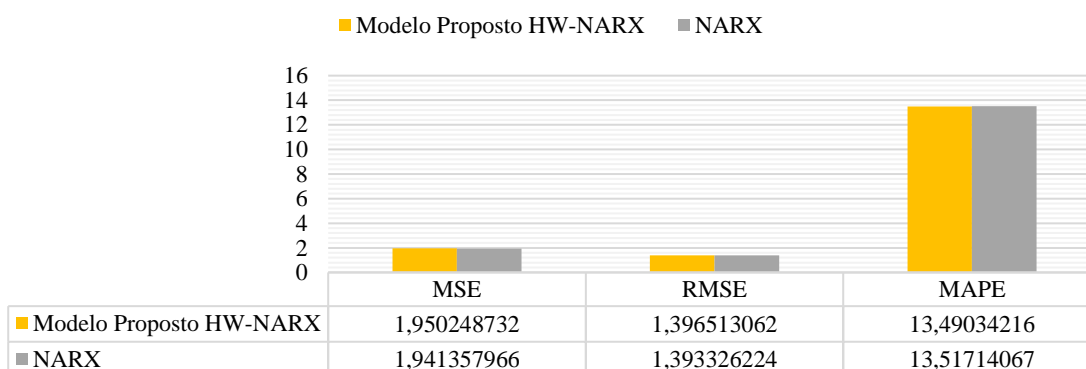
O artigo é *Open Access* e pode ser acessado pelo seguinte link: <https://www.journalijdr.com/application-narx-model-forecasting-wind-speed-wind-energy-generation>.

APÊNDICE B – COMPARATIVO DE ERROS MSE, RMSE E MAPE DE PERFORMANCE DE TREINAMENTO PARA OS ALGORITMOS NARX E O MODELO PROPOSTO HW-NARX


Horizonte de 10 Minutos 5 passos à frente



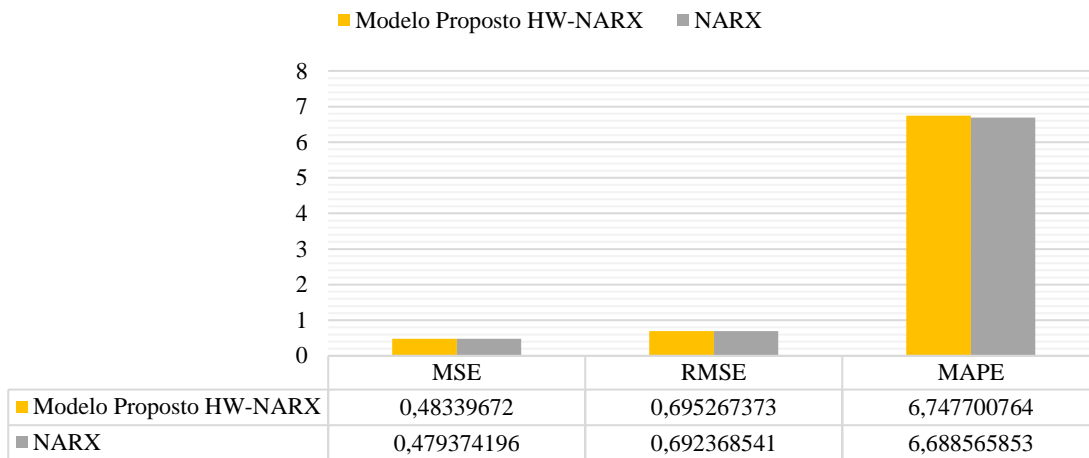
Horizonte de 10 Minutos 10 passos à frente



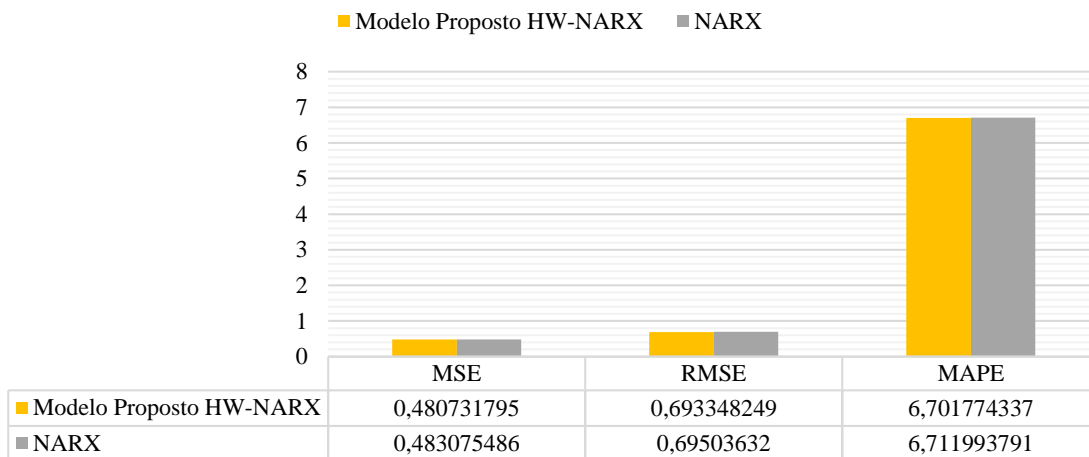
Horizonte de 10 Minutos 30 passos à frente



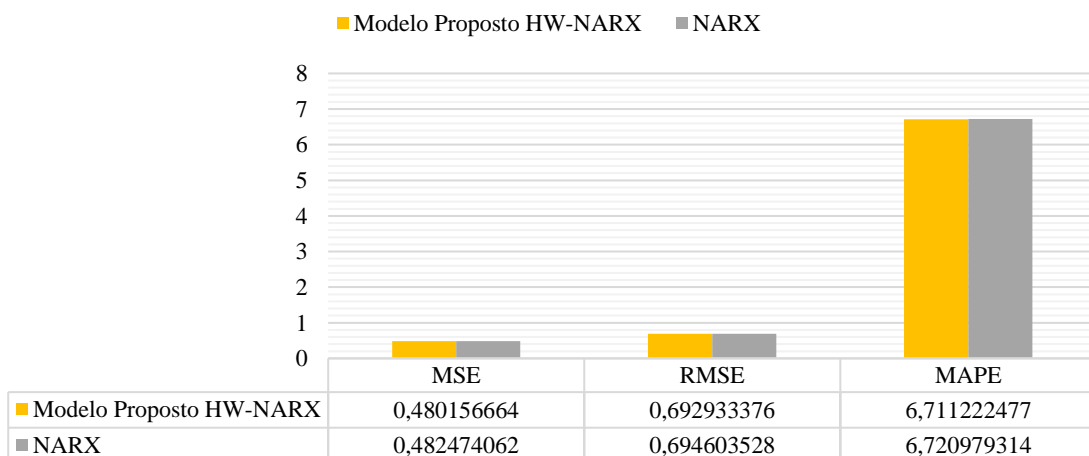
Horizonte de 1 Hora 5 passos à frente



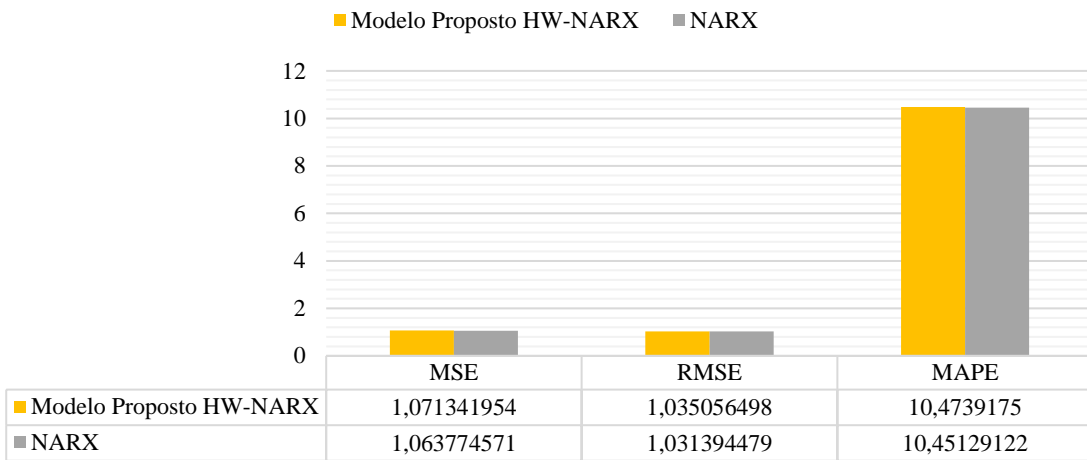
Horizonte de 1 Hora 10 passos à frente



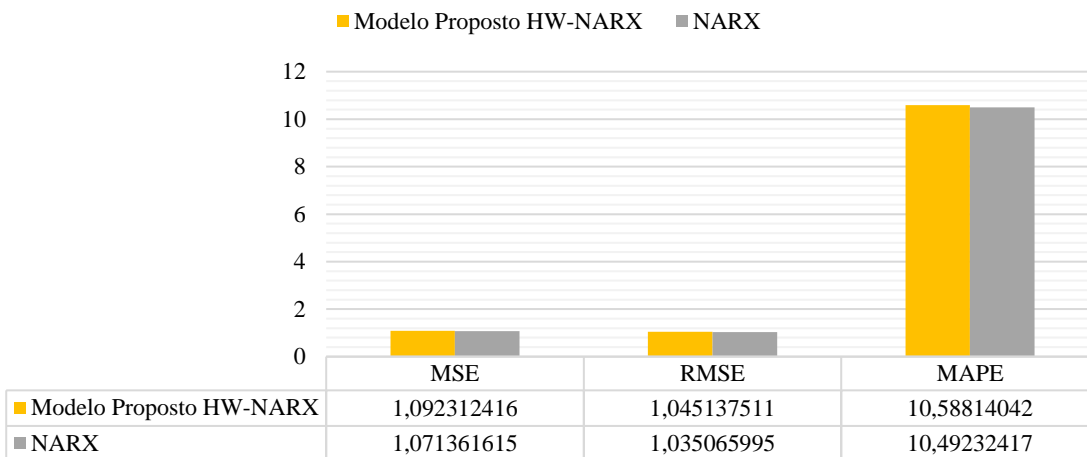
Horizonte de 1 Hora 30 passos à frente



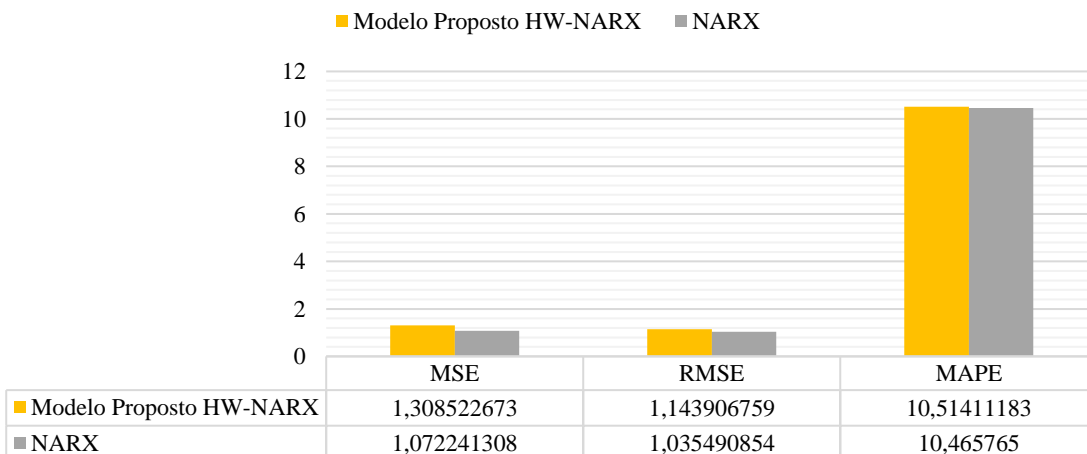
Horizonte de 1 Dia 5 passos à frente



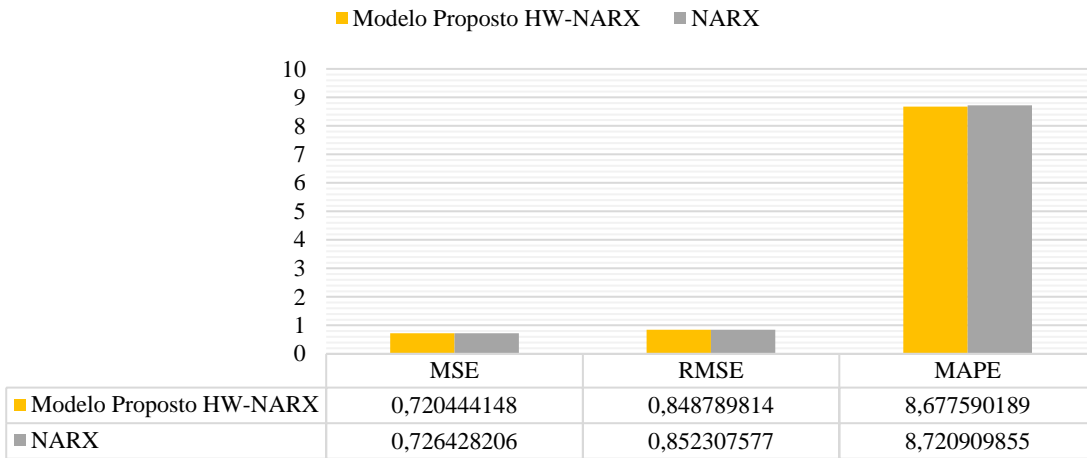
Horizonte de 1 Dia 10 passos à frente



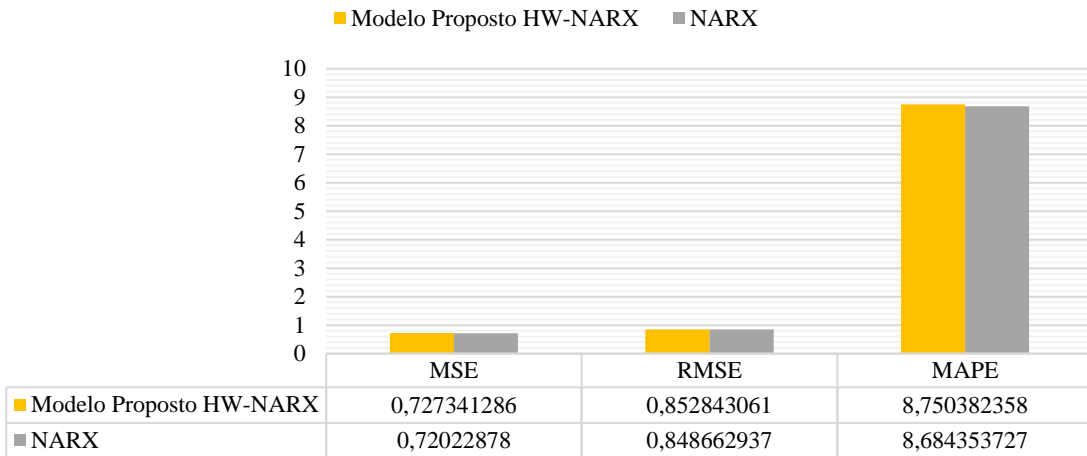
Horizonte de 1 Dia 30 passos à frente



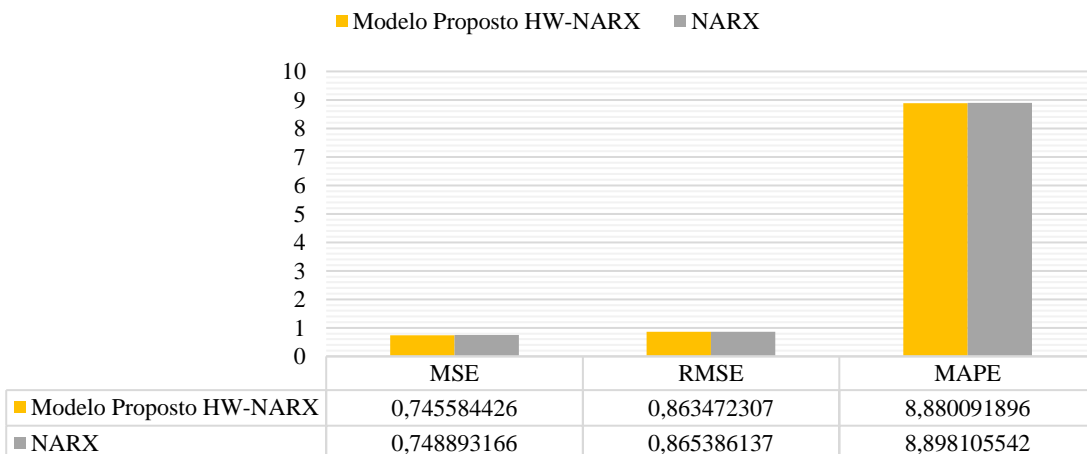
Horizonte de 1 Semana 5 passos à frente



Horizonte de 1 Semana 10 passos à frente




Horizonte de 1 Semana 30 passos à frente




**APÊNDICE C – PARÂMETROS UTILIZADOS NO ALGORITMO HOLT-WINTERS
PARA A SUAUIZACÃO E PREVISÃO DA VELOCIDADE DO VENTO**


Horizonte de 10 Minutos (Alfa)




Horizonte de 10 Minutos (Beta)




Horizonte de 10 Minutos (Gama)



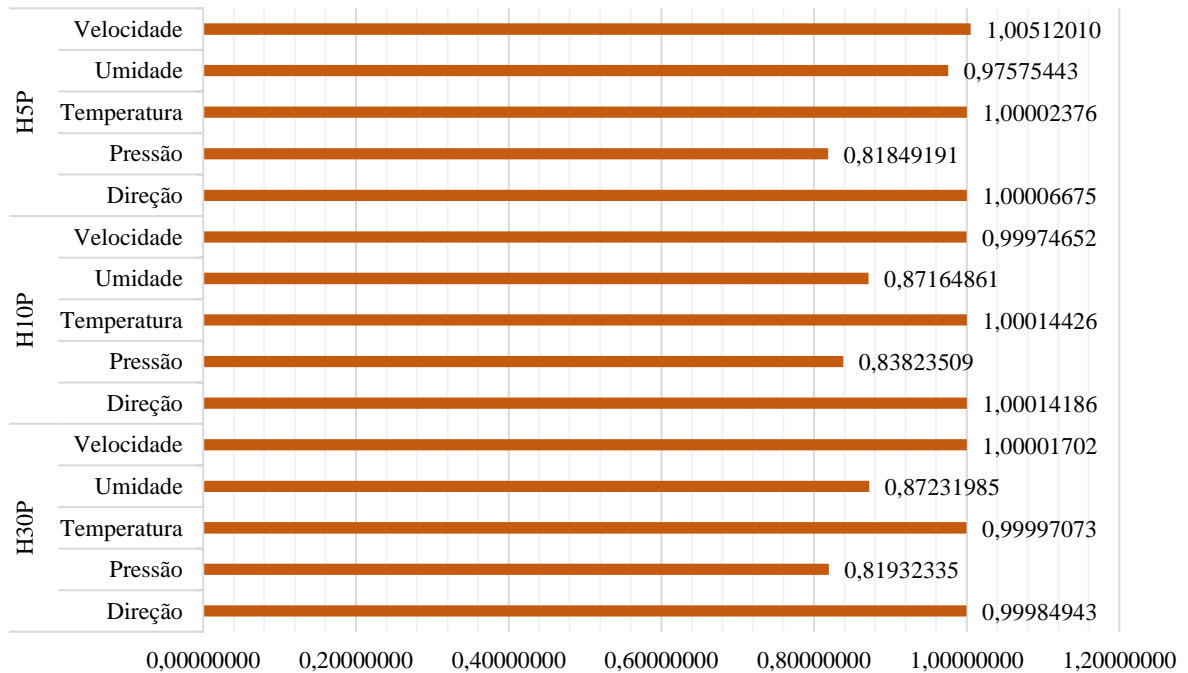
Horizonte de Horas (Alfa)




Horizonte de Horas (Beta)




Horizonte de Horas (Gama)




Horizonte de Dias (Alfa)




Horizonte de Dias (Beta)




Horizonte de Dias (Gama)



Horizonte de Semanas (Alfa)



Horizonte de Semanas (Beta)



Horizonte de Semanas (Gama)

