



UNILAB

Universidade da Integração Internacional
da Lusofonia Afro-Brasileira

**UNIVERSIDADE DA INTEGRAÇÃO INTERNACIONAL DA LUSOFONIA AFRO-
BRASILEIRA**

**INSTITUTO DE ENGENHARIAS E DESENVOLVIMENTO SUSTENTÁVEL
CURSO DE ENGENHARIA DE ENERGIAS**

MARCUS CANUTTO FARIAS SILVA

**ESTIMATIVA DA VELOCIDADE DO VENTO UTILIZANDO MÉTODOS LINEARES
E NÃO LINEARES**

REDENÇÃO

2022

MARCUS CANUTTO FARIAS SILVA

**ESTIMATIVA DA VELOCIDADE DO VENTO UTILIZANDO MÉTODOS LINEARES
E NÃO LINEARES**

Monografia apresentada ao curso de Engenharia de Energias do Instituto de Engenharias e Desenvolvimento Sustentável da Universidade da Integração Internacional da Lusofonia Afro-Brasileira, como requisito parcial para obtenção do Título de Bacharel em Engenharia de Energias.

Orientador: Prof. Dr. Vandilberto Pereira Pinto.

REDENÇÃO

2022

Universidade da Integração Internacional da Lusofonia Afro-Brasileira
Sistema de Bibliotecas da UNILAB
Catalogação de Publicação na Fonte.

Silva, Marcus Canutto Farias.

S696a

Estimativa da velocidade do vento utilizando métodos lineares e não lineares / Marcus Canutto Farias Silva. - Redenção, 2022.
46f: il.

Monografia - Curso de Engenharia de Energias, Instituto de Engenharias e Desenvolvimento Sustentável, Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Redenção, 2022.

Orientador: Prof. Dr. Vandilberto Pereira Pinto.

1. Identificação de sistemas. 2. Previsão. 3. Velocidade dos ventos. I. Título

CE/UF/BSP

CDD 624.1

MARCUS CANUTTO FARIAS SILVA

ESTIMATIVA DA VELOCIDADE DO VENTO UTILIZANDO MÉTODOS LINEARES E
NÃO LINEARES

Monografia apresentada ao curso de Engenharia de Energias do Instituto de Engenharias e Desenvolvimento Sustentável da Universidade da Integração Internacional da Lusofonia Afro-Brasileira, como requisito parcial para obtenção do Título de Bacharel em Engenharia de Energias.

Aprovada em: 11/02/2022.

BANCA EXAMINADORA



Prof. Dr. Vandilberto Pereira Pinto

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)



Prof. Dr. Antonio Alisson Pessoa Guimarães

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)



Prof. Dr. Francisco Olimpio Moura Carneiro

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)

Francisco Olimpio Moura Carneiro
Professor do Magistério Superior
Instituto de Engenharias e Desenvolvimento
Sustentável - SIAPE: 1148304

AGRADECIMENTOS

Primeiramente à Deus, por me agraciar com saúde e me dar forças para sempre continuar em frente.

Ao Prof. Dr. Vandilberto Pereira Pinto, pela excelente orientação e cooperação para com este trabalho.

A minha família, em especial a minha mãe Maria do Socorro Farias Silva que sempre esteve presente e se esforçou e fez de tudo para que eu continuasse seguindo em frente, aos meus irmãos Cintia Farias Silva de Castro, Edson Brasil da Silva Filho e meu cunhado Luiz Aciole Vasconcelos de Castro, por sempre terem sido exemplos para mim em toda a minha vida. E para minha avó, Maria Dária Abreu Farias, que a pouco mais de um ano fez sua viagem para junto do pai celestial.

A minha namorada, Andreza Silva Barbosa, pelo companheirismo, por se fazer presente em toda a construção deste trabalho, me dar forças e encorajar em todos os momentos difíceis além de fazer-me lembrar de toda a minha capacidade.

Aos meus amigos, Gabriel Yves de Melo Raulino, Matheus Lucas Maia de Freitas e Dara Ellen Muniz Rocha, por se fazerem presente e contribuído para que eu alcançasse essa etapa.

A todos meus professores, que contribuíram direta e indiretamente para minha formação profissional e acadêmica.

Aos professores participantes da banca examinadora Prof. Dr. Antonio Alisson Pessoa Guimarães e Prof. Dr. Francisco Olimpio Moura Carneiro pelo tempo, consideração e todas colaborações que enriquecem ainda mais este trabalho.

“A ciência nunca resolve um problema sem criar pelo menos outros dez.” – George Bernard Shaw

RESUMO

Dentre as fontes de energia da matriz elétrica brasileira, a energia eólica está em constante evolução. Por depender diretamente da velocidade do vento, seja para o controle da turbina em si quanto para a consistência da energia inserida no sistema elétrico, o desenvolvimento de sistemas de previsão da velocidade do vento permite que seja possível tornar o processo mais eficiente e antecipar possíveis perdas na geração de energia. Diante disto, o objetivo deste trabalho destina-se realizar previsões de velocidade do vento, referentes à um horizonte de até 7 dias que varia de acordo com o período amostral empregado, utilizando-se métodos matemáticos lineares e não-lineares. Com o propósito de utilizar os métodos propostos, buscou-se o banco de dados do INMET (*Instituto Nacional de Meteorologia*) que armazena dados de velocidade do vento, temperatura, radiação, umidade do ar, entre outras, referente a estação meteorológica automática (EMA) do município de Fortaleza-CE. As simulações foram desenvolvidas com o auxílio da ferramenta MATLAB, a partir de métodos lineares BJ e OE (*Box-Jenkins e Output Error*) e não-linear NARX (*Nonlinear Autoregressive Model with Exogenous Variables*) para evidenciar qual o melhor de estimação de parâmetros. Os modelos foram comparados e avaliados no intuito de verificar qual teria o melhor desempenho. O método linear BJ foi o que apresentou uma maior precisão, de 99,99% e o erro médio quadrático, *Mean Square Error*, MSE de 0,03647 para o intervalo de 25 dias do mês de agosto. Em comparação com os métodos NARX e OE, que tiveram uma acurácia de 99,37% e 78,32%, respectivamente, para o mesmo período amostral. Os resultados evidenciam que, através do método de identificação de sistemas, é possível fazer uma previsão expressiva.

Palavras-chave: Identificação de sistemas, previsão, velocidade do vento.

ABSTRACT

Among the energy sources of the Brazilian electrical matrix, wind energy is constantly evolving. As it depends directly on the wind speed, either for the control of the turbine itself or for the consistency of the energy inserted in the electrical system, the development of wind speed prediction systems makes it possible to make the process more efficient and anticipate possible losses in energy generation. Therefore, the objective of this work is to carry out wind speed forecasts, referring to a horizon of up to 7 days that varies according to the sampling period used, using linear and non-linear mathematical methods. In order to use the proposed methods, the INMET (National Institute of Meteorology) database was searched, which stores data on wind speed, temperature, radiation, air humidity, among others, referring to the automatic weather station (EMA) in the city of Fortaleza-CE. The simulations were developed with the help of the MATLAB tool, using linear methods BJ and OE (Box-Jenkins and Output Error) and non-linear NARX (Nonlinear Autoregressive Model with Exogenous Variables) to show the best parameter estimation. The models were compared and evaluated in order to verify which would have the best performance. The BJ linear method showed the highest precision, 99.99% and, Mean Square Error, MSE of 0.03647 for the 25-day interval in August. In comparison with the NARX and OE methods, which had an accuracy of 99.37% and 78.32%, respectively, for the same sample period. The results show that, through the system identification method, it is possible to make an expressive prediction.

Keywords: Systems identification. Forecast. Wind speed.

LISTA DE FIGURAS

Figura 1	– Diagrama esquemático modelo BJ.....	20
Figura 2	– Diagrama esquemático modelo OE.....	21
Figura 3	– Rede NARX com arquitetura genética.....	24
Figura 4	– Distribuição dos ventos globais.....	25
Figura 5	– Matriz elétrica brasileira 2020.....	26
Figura 6	– Estação Meteorológica Automática.....	28
Figura 7	– Divisão dos dados entre treinamento e validação.....	31
Figura 8	– Resultado modelo OE de agosto 25 dias.....	32
Figura 9	– Resultado modelo OE de setembro 25 dias.....	33
Figura 10	– Resultado modelo OE de outubro 15 dias.....	33
Figura 11	– Resultado modelo BJ de agosto 25 dias.....	35
Figura 12	– Resultado modelo BJ de setembro 20 dias.....	36
Figura 13	– Resultado modelo BJ de outubro 15 dias.....	36
Figura 14	– Resultado modelo NARX de agosto 25 dias.....	38
Figura 15	– Resultado modelo NARX de setembro 25 dias.....	39
Figura 16	– Resultado modelo NARX de outubro 25 dias.....	39

LISTA DE TABELAS

Tabela 1 – Capacidade instalada de geração elétrica no Brasil (MW).....	14
Tabela 2 – Ranking de países por potência acumulada 2020.....	27
Tabela 3 – Ranking de países por capacidade instalada 2020.....	27
Tabela 4 – Resultados modelo OE.....	32
Tabela 5 – Resultados modelo BJ.....	35
Tabela 6 – Resultados Modelo NARX.....	37

LISTA DE ABREVIATURAS E SIGLAS

OE	<i>Output Error</i>
MLP	<i>Multi Layer Perceptron</i>
BJ	<i>Box-Jenkins</i>
NARX	<i>Nonlinear AutoRegressive model with exogenous inputs</i>
BEN	Balanço Energético Nacional
EPE	Empresa de Pesquisa Energética
EMA	Estação Meteorológica Automática
MSE	<i>Mean Square Error</i>
EMC	Estação Meteorológica Convencional

SUMÁRIO

1 INTRODUÇÃO.....	13
1.1 Revisão bibliográfica.....	14
1.1.1 Características do vento e previsão	14
1.2 Objetivos.....	16
1.2.1 Objetivo Geral.....	16
1.2.2 Objetivos específicos.....	16
1.2.3 Justificativa.....	16
1.2.4 Organização do trabalho.....	17
2 IDENTIFICAÇÃO DE SISTEMAS.....	18
2.1 Modelos Paramétricos Lineares.....	19
2.1.1 Modelo <i>Box-Jenkins</i>.....	20
2.1.2 Modelo <i>Output Error</i>.....	21
2.2 Modelos Paramétricos Não Lineares.....	22
2.2.1 Modelo Não Linear Autorregressivo com entradas exógenas - NARX.....	23
3 VENTO E ENERGIA EÓLICA.....	25
4 DADOS METEOROLÓGICOS.....	27
5 RESULTADOS E DISCUSSÃO.....	30
5.1 Modelo OE.....	32
5.2 Modelo BJ.....	34
5.3 Modelo NARX.....	37
6 CONCLUSÃO.....	40
REFERÊNCIAS.....	42

1 INTRODUÇÃO

A energia elétrica é um dos insumos essenciais para o desenvolvimento socioeconômico de um país, de tal forma que a quantidade de energia consumida por uma nação muitas vezes reflete o seu nível de desenvolvimento (SATHYAJITH, 2014). De acordo com o Anuário elaborado pela Empresa de Pesquisa Energética (EPE, 2021) com referência ao ano de 2020, observado na Tabela 1, a capacidade instalada de geração de energia elétrica no Brasil é de 174.737 MW, apresentando um aumento de 2,7% em relação ao ano de 2019.

Tabela 1: Capacidade instalada de geração elétrica no Brasil (MW)

	2016	2017	2018	2019	2020	Δ% (2020/2019)	Part. % (2020)	
Total	150.338	157.112	164.503	170.118	174.737	2,7	100,0	Total
Usinas Hidrelétricas	91.499	94.662	98.287	102.999	103.027	0,0	59,0	Hydropower Plants
PCH	4.941	5.020	5.157	5.291	5.429	2,6	3,1	SHP
CGH	484	594	695	768	816	6,2	0,5	CHG
Gás Natural	12.965	12.980	13.359	13.385	14.927	11,5	8,5	Natural Gas
Derivados de Petróleo	8.845	8.792	7.549	7.670	7.696	0,3	4,4	Petroleum Products
Carvão	3.389	3.324	2.858	3.228	3.203	-0,8	1,8	Coal
Usinas Nucleares	1.990	1.990	1.990	1.990	1.990	0,0	1,1	Nuclear Power Plants
Biomassa	13.913	14.289	14.569	14.703	15.011	2,1	8,6	Biomass
Usinas Eólicas	10.124	12.283	15.378	15.378	17.131	11,4	9,8	Wind Power Plants
Solar	24	935	2.473	2.473	3.287	32,9	1,9	Solar Power Plants
Outras	2.163	2.243	2.188	2.234	2.221	-0,6	1,3	Others

Fonte: Empresa de Pesquisa Energética (EPE, 2021)

Com a crescente preocupação nas mudanças climáticas e preços voláteis do petróleo, a utilização de fontes de energia renováveis aumenta gradativamente. No Brasil, como evidenciado na Tabela 1, a contribuição da energia eólica na matriz elétrica nacional em 2020 é de 9,8%, correspondendo a uma capacidade instalada de 17.131 MW. Em 2019 a energia eólica obtinha uma participação de 8,6%, comparando a potência instalada entre 2019 e 2020 constata-se um aumento de 11,4%. Entre 2009 e 2015 a fonte eólica fez parte de quatorze leilões energéticos, sendo contratados 14.000 MW em novos projetos.

A geração eólica depende fundamentalmente da velocidade do vento incidente no aerogerador, que não pode ser controlada por apresentar grandes variabilidades (HIRUMA, 2017). O desenvolvimento e melhoramento de métodos para a previsão da velocidade do vento são de fundamental importância desde a prospecção até a distribuição de energia oriunda da fonte eólica.

Tendo em vista essa problemática, este trabalho aplica modelos de previsão utilizando-se um banco de dados com valores médios diários de velocidade do vento da região de Fortaleza no estado do Ceará, a partir de métodos de identificação de sistemas lineares e não lineares para estimar a velocidade do vento.

1.1 Revisão bibliográfica

1.1.1 Características do vento e previsão

O vento, dentre muitas definições existentes, pode ser definido como massa de ar em movimento devido ao aquecimento e arrefecimento da superfície terrestre e diferença de pressão, desloca-se da alta para baixa pressão provocando o movimento horizontal do ar (LYRA *et al*, 2016). Numa região de temperatura mais elevada, a pressão atmosférica será menor, pois a massa de ar que se encontra naquela região, irá tornar-se mais leve e, por conseguinte eleva-se para níveis mais elevados da atmosfera (movimento convectivo) (SILVA, 2016).

De acordo com Molion e Bernardo (2002), o vento resulta de variações dos gradientes horizontais de pressão atmosférica, por ser responsável pelo transporte horizontal (advecção) de calor latente e sensível, se torna uma das variáveis meteorológicas com maior importância.

Segundo Silva (2018), ventos locais estão envolvidos com as brisas (marítima e terrestre), aos ventos anabáticos, que transportam ar devido o aquecimento por insolação da montanha ou encosta e ventos catabáticos, que transportam o ar devido a ação da gravidade. Ainda de acordo com Silva (2018) os ventos globais vão desde o Equador até os polos, esse transporte de massas de ar depende da advecção do vento.

Segundo Silva (2003), o calor é absorvido pela atmosfera em baixas latitudes (30° N e 30° S), enquanto que em outros lugares a absorção é menor. O calor das

regiões com temperaturas elevadas, exemplo o Equador, se direciona para regiões com maior necessidade, como os polos. Esse fluxo proporciona uma maior distribuição de temperatura.

O interesse no desenvolvimento de modelos de previsão de velocidades de vento e geração eólica tem aumentado substancialmente, não só no mundo como também no Brasil. Este interesse tem sido despertado pelo aumento de produção de energia elétrica a partir das forças dos ventos e para acompanhamento meteorológico (OLIVEIRA, 2008). De acordo com Soman et al (2010), a previsão do vento pode ser classificada nas seguintes categorias:

- Previsões de curtíssimo prazo, poucos minutos a frente;
- Previsões de curto prazo, 72 horas até 3 dias à frente;
- Previsões de médio prazo, no máximo 10 dias a frente;
- Previsões de longo prazo, acima de 10 dias.

Segundo Santos (2019), além das previsões do vento terem implicações na capacidade de energia elétrica, também trazem benefícios em outros setores da sociedade, principalmente para aeroportos, atividades esportivas e no lazer em geral.

De acordo com Gouveia (2011), um dos maiores gargalos da energia eólica, em comparação com as demais fontes de energia tradicionais, é a sua dependência do vento. Essa dependência engloba todas as escalas temporais, principalmente as escalas de milissegundos a segundos, para o controle da turbina em si, e a de minutos a semanas, que é importante para a consistência da energia eólica na rede elétrica.

Visto isso, o estudo de métodos de previsão da velocidade do vento é de suma importância para diversos setores da sociedade. Quão mais precisos forem esses métodos, melhores serão os planejamentos envolvendo energia eólica, conseqüentemente, menores serão as perdas. Alguns trabalhos com esse enfoque são explanados a seguir.

Jensen (1994), faz comparações utilizando modelos autorregressivos entre a previsão direta de energia eólica em relação às previsões da velocidade do vento, evidenciam que as previsões da velocidade do vento são importantes para horizontes que variam entre 8-12 horas.

Sfetsos (2002), utilizou redes neurais e o modelo ARIMA (*Autoregressive Integrated Moving Average* – ARIMA) para a previsão da velocidade do vento nas regiões do Reino Unido e Grécia no horizonte de uma hora. Jiang et al (2013), utilizaram um novo método de séries temporais para prever velocidade do vento a curto prazo. O método compreende os conceitos de quebras estruturais e inferências Bayesianas, assim, a informação antecipada da velocidade do vento é incorporada ao modelo. Os resultados evidenciaram que esse método aumenta o desempenho da previsão. Gouveia (2011), desenvolve modelos de previsão de velocidades de vento e geração de energia elétrica tendo como base a previsão de velocidades com a curva de potência dos aerogeradores. Os modelos de previsão utilizados foram: Redes Neurais Artificiais (RNA), Lógica Fuzzy (LF) e Análise Wavelet. A região de estudo foi a do nordeste brasileiro.

1.2 Objetivos

1.2.1 Objetivo Geral

Aplicar os métodos lineares (*Box-Jenkins* e *Output Error*) e não linear (NARX), para a prever a velocidade do vento a partir de dados de uma estação meteorológica do município de Fortaleza/CE.

1.2.2 Objetivos Específicos

- Aplicar a modelagem linear dos modelos *Box-Jenkins* e *Output Error* ao banco de dados;
- Aplicar a modelagem não-linear NARX ao banco de dados;
- Comparar os modelos lineares e não-lineares.

1.2.3 Justificativa

Quando se aborda a temática de energias renováveis, é notório que a participação da energia eólica está em constante ascensão. O desenvolvimento de métodos de previsão da velocidade do vento influencia positivamente de forma direta no que diz respeito à prospecção, produção e distribuição de energia elétrica da fonte

eólica. A maior confiabilidade nas etapas do processo, possibilita um maior investimento nessa fonte renovável, reduzindo a produção de energia oriunda de combustíveis fósseis.

Visto isso, a aplicação e desenvolvimento de métodos de previsão da velocidade do vento podem auxiliar em um maior investimento a esta fonte de energia, tendendo a favorecer a uma maior desenvoltura ao setor de energia renovável.

1.2.4 Organização do trabalho

Este trabalho está dividido em 6 capítulos, descritos a seguir:

- Capítulo 1: introduz o tema deste trabalho de conclusão de curso, revisão bibliográfica e seus objetivos gerais e específicos.
- Capítulo 2: definição de identificação de sistemas, modelos paramétricos lineares e não lineares juntamente com seus respectivos modelos.
- Capítulo 3: define as características do vento, sua relação direta com a energia eólica e sua contribuição no cenário atual de energia brasileiro.
- Capítulo 4: conceito de banco de dados, estações meteorológicas e detalhamento dos órgãos responsáveis pelo armazenamento destes dados.
- Capítulo 5: resultados obtidos após aplicação dos métodos lineares e não lineares, bem como o realce dos melhores resultados obtidos em cada método.
- Capítulo 6: apresenta a conclusão e demais considerações referentes ao trabalho.

2 IDENTIFICAÇÃO DE SISTEMAS

Modelos matemáticos têm sido usados com diferentes finalidades durante a história, como por exemplo: entender e explicar modelos observados na natureza quanto em sistemas sociais, biomédicos, equipamentos, projetos de sistemas de monitoramento e controle, predição, estimação de estados, simulação e treinamento, sendo um exemplo disso os simuladores de voo (AGUIRRE, 2004).

A modelagem matemática tem como finalidade descrever fenômenos naturais ou físicos por meio de equações matemáticas. Na literatura técnica há dois tipos de abordagem comumente utilizadas para modelar matematicamente a dinâmica de um sistema, sendo elas: a modelagem conceitual, e por identificação de sistemas (ROMIO *et al.*, 2012).

A abordagem conceitual é também conhecida como modelagem pela física ou natureza do processo, nela é necessário conhecer bem o sistema de estudo, bem como as leis da física que regem o problema a ser modelado (AGUIRRE, 2004). A modelagem conceitual não é utilizada em sistemas complexos ou com vários processos, as equações que viriam a ser utilizadas seriam extremamente complexas podendo chegar a serem desconhecidas, o que resultaria em um aumento considerável de tempo para analisá-las, não se tornando eficaz para a sua implementação. Para sistemas com essas características, utiliza-se a modelagem por identificação de sistemas. Na qual é também conhecida como caixa branca, em que faz-se necessário conhecer bem o sistema com o qual se está trabalhando (Ost, 2015).

Conforme Romio et al. (2012), na identificação de sistemas existem duas formas para construção de modelos matemáticos: modelagem caixa preta e caixa cinza. Na modelagem caixa preta somente os dados de entrada e saída do processo são utilizados durante a identificação. Uma vantagem da utilização dessa técnica é a facilidade na obtenção de um modelo e a flexibilização de escolha da estrutura que melhor se adeque para o objetivo da modelagem.

A modelagem caixa cinza consiste em ter um conhecimento prévio do sistema a ser modelado. Um conjunto de dados é utilizado para auxiliar no conhecimento do

sistema, entretanto, essa informação não se encontra durante a identificação, ou seja, este modelo está situado entre a modelagem física e a identificação.

De acordo com Ljung (1999), os modelos desenvolvidos através da teoria da identificação dos sistemas são divididos em três grupos: modelos paramétricos (modelo Auto-Regressivo com entradas eXternas (ARX), modelo Auto-Regressivo Integrado Média móvel com entradas Exógenas (ARIMAX), Output Error (OE), e o modelo Box Jenkins (BJ); modelos não-paramétricos (modelos de processos, modelos de correlação, modelos não-lineares); modelos no domínio da frequência.

2.1 Modelos Paramétricos Lineares

Segundo Aguirre (2004), são considerados modelos paramétricos lineares aqueles que possuem parâmetros, ou seja, coeficientes que os caracterizam e precisam ser estimados. A estrutura geral representada em tempo discreto pode ser representada da seguinte forma:

$$A(q)y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}v(k) \quad 2.1$$

$A(q)$, $B(q)$, $C(q)$, $D(q)$, e $F(q)$ representam os seguintes polinômios:

$$A(q) = 1 - a_1q^{-1} - \dots - a_{n_y}q^{-n_y} \quad 2.2$$

$$B(q) = b_1q^{-1} + \dots + b_{n_u}q^{-n_u} \quad 2.3$$

$$C(q) = 1 - c_1q^{-1} + \dots + c_{n_v}q^{-n_v} \quad 2.4$$

$$D(q) = 1 - d_1q^{-1} + \dots + d_{n_d}q^{-n_d} \quad 2.5$$

$$F(q) = 1 - f_1q^{-1} + \dots + f_{n_f}q^{-n_f} \quad 2.6$$

Onde: q^{-1} é o operador de atraso, de forma que $y(k)q^{-1} = y(k - 1)$, e $v(k)$ é o ruído branco

Os termos n_y, n_u, n_d, n_e e n_f são as ordens dos polinômios enquanto: $a_1 \dots a_{n_y}, b_1 \dots b_{n_u}, c_1 \dots c_{n_v}, d_1 \dots d_{n_e}$ e $f_1 \dots f_{n_f}$ são parâmetros que necessitam serem estimados.

2.1.1 Modelo *Box-Jenkins*

O modelo *Box-Jenkins* (BJ) é obtido a partir da Equação 2.1, adotando $A(q) = 1$, $C(q)$, $D(q)$ e $F(q)$ sendo polinômios arbitrários, assim tem o seguinte resultado:


$$y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}v(k) \quad 2.7$$

Substituindo as funções de transferência $\frac{B(q)}{F(q)}$ por $H(q)$ e $\frac{C(q)}{D(q)}$ por $W(q)$, tem-se:

$$y(k) = H(q)u(k) + W(q)v(k) \quad 2.8$$

A Figura 1 ilustra a representação esquemática do modelo BJ através do diagrama de blocos (FREITAS, 2019.)

Figura 1: Diagrama esquemático modelo BJ.



Fonte: Adaptado de (FREITAS, 2019.)

2.1.2 Modelo *Output Error*

De acordo com Machado (2014), o modelo *Output Error* (OE) é também obtido da Equação geral 2.1, fazendo $A(q) = C(q) = D(q) = 1$ e $B(q)$, $F(q)$ são polinômios aleatórios. Assim, tem-se:

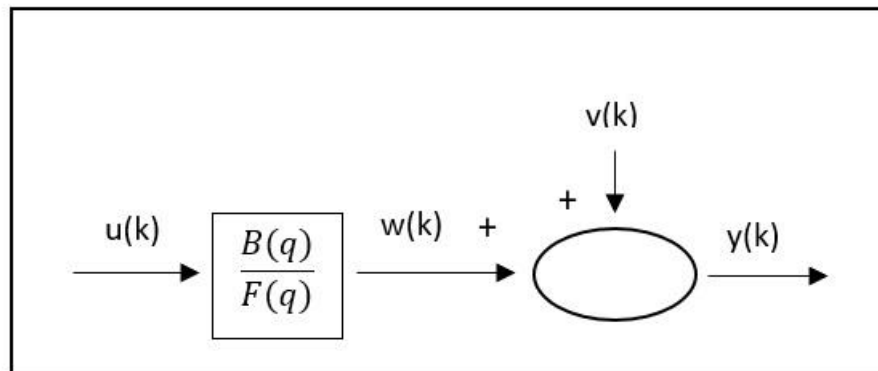
$$y(k) = \frac{B(q)}{F(q)}u(k) + v(k) \quad 2.9$$

Substituindo a função de transferência $\frac{B(q)}{F(q)}$ por $H(q)$, tem-se:

$$y(k) = H(q)u(k) + v(k) \quad 2.10$$

A seguir, a Figura 2 descreve o modelo OE através do diagrama de blocos.

Figura 2: Diagrama esquemático modelo OE.



Fonte: Adaptado de (MACHADO, 2014.)

2.2 Modelos Paramétricos Não Lineares

De acordo com Aguirre (2004), em muitos casos aproximações lineares são suficientes para aplicações práticas. Porém, numa série de casos, modelos lineares não serão satisfatórios. Estes modelos são estruturas flexíveis que basicamente durante a etapa de treinamento ajustam seus parâmetros internos de acordo com os dados de entrada e saída, reproduzindo diferentes regimes dinâmicos para diferentes pontos de operação (CAJUEIRO, 2012).

Uma representação geral de um modelo não-linear é definida por:

$$y = \varphi(x, \delta) + \varepsilon \quad 2.11$$

Onde x e δ são variáveis explicativas, ε é o componente de distúrbio estocástico e φ é uma função que associa variáveis dependentes à variável y (SANTOS, 2019). De acordo com Coelho (2002), dentre as representações não-lineares as que recebem maior destaque são: modelos baseados em redes neurais (BRAGA et al., 2000; HAYKIN, 1994; AMARAL, 2001), modelos NARMAX polinomiais (Barroso, 2001), modelos contínuos (FREITAS, 2001), Wavelets (BILLINGS and COCA, 1999a,b).

2.2.1 Modelo Não Linear Autorregressivo com entradas exógenas - NARX.

Rede neural artificial não linear auto-regressiva com entrada externa (NARX) é uma rede Recorrente ou Realimentada, também conhecida como redes de Hopfield, caracteriza-se pelo fato de que as saídas de uma camada neural podem realimentar a camada de entrada (SANTOS, 2019).

A rede NARX considera diversas camadas de uma rede *Multi Layer Perceptron*, MLP, podendo ser aplicada de forma eficaz em um grande número de problemas de identificação de sistemas. De acordo com Santos (2019) inicialmente caracteriza-se como uma rede *Feedforward*, ou seja, a informação segue em direção a saída, a diferença é que sua camada de saída realimenta a entrada.

Pode-se destacar também, o delay, ou atraso temporal, a variável Z. O atraso da rede serve como uma memória que proporciona valores de entrada atuais e valores anteriores a eles (HAYKIN, 2008). As redes NARX, além de apresentarem um bom desempenho para aprender as dependências de longa duração, possuem convergência mais rápida e generalizam melhor do que outras redes recorrentes (JÚNIOR, 2006).

Considere que a rede seja composta por uma sequência de entradas $u_q(n)$ definida por:

$$u_q(n) = [u(n), u(n + 1), \dots, u(n + d_u - 1)] \quad 2.12$$

e suas saídas:

$$y_q(n) = [y(n), y(n + 1), \dots, y(n + d_y - 1)] \quad 2.13$$

o modelo é definido da seguinte forma:


$$y(n + q) = f(y(n + d_y - 1), \dots, y(n), u(n + d_u - 1), \dots, u(n)) \quad 2.14$$

Substituindo n por $n-q+1$, temos:

$$y(n + 1) = f(y(n), \dots, y(n - d_y + 1), u(n), \dots, u(n - d_u + 1)) \quad 2.15$$

Na Figura 3 é exposto uma representação esquemática de uma rede NARX genérica, evidenciando suas entradas, neurônios, ligações e realimentação.

Figura 3: Rede NARX com arquitetura genérica



Fonte: Huang et al (2007).

A rede NARX consegue descrever comportamentos dinâmicos (sistemas variantes em relação ao tempo), identificação de sistemas, possibilidade de armazenamento de informações e capacidade de memorizar relacionamentos (SILVA, SPATTI & FLAUZINO, 2010).

A rede NARX pode ser treinada e utilizada em um dos seguintes modos de operação (NARENDRA, PARTHASARATHY, 1990):

- Modo de Identificação Paralelo: chamado de modo recorrente, a saída estimada é realimentada e incluída na saída do regressor;
- Modo de Identificação Série-Paralelo: chamado de modo não-recorrente, a saída do regressor é formada somente por valores observados (medidos) da saída do sistema.

A Figura 3 mostrada acima é a representação exclusiva do Modo de Identificação Paralelo. De acordo com Menezes e Barreto (2006), a rede é bastante


utilizada com sucesso em diversos problemas, tais como: modelagem de entrada-saída, trocadores de calor, plantas de tratamento da água servidas, entre outros.

3 VENTO E ENERGIA EÓLICA

O aproveitamento da energia cinética dos ventos vem sendo utilizada pela humanidade há mais de 3000 anos, seja através dos moinhos de vento ou bombeamento de água em atividades agrícolas. O vento é o movimento das massas de ar na atmosfera devido a incidência desigual de radiação solar, aos movimentos da Terra e à influência dos efeitos térmicos (GOMES, 2017).

A diferença da radiação solar em locais distintos provoca diferenças de temperatura do ar, que resulta no movimento de massas de ar das zonas de alta pressão para as zonas de baixa pressão atmosférica. O ar quente e de maior pressão situado nas zonas mais próximas a linha do equador, se desloca para as regiões polares, onde o clima é mais frio. Conseqüentemente, os ventos frios dos polos se deslocam para as áreas tropicais. A Figura 4 ilustra a localização dos ventos de maior e menor temperatura, bem como o seu fluxo de escoamento.

Figura 4: Distribuição dos ventos globais.

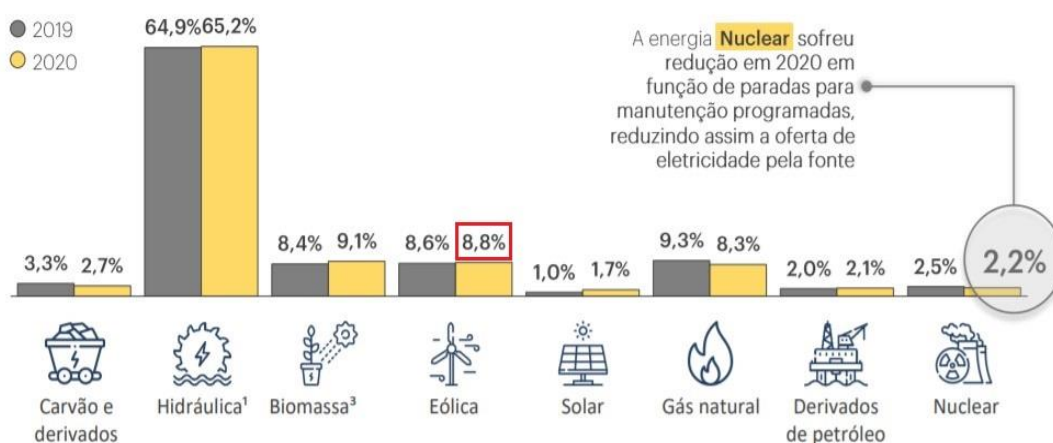


Fonte: CEPEL, 2001.

Além dos ventos em escala global, existem os ventos litorâneos. O motivo de muitos parques eólicos serem instalados próximo a costa é devido a diferença de temperatura existente entre a terra e o mar. Durante o dia a terra retém mais calor que o mar, portanto, existe um fluxo de ar que se desloca do mar em sentido a terra. Durante a noite ocorre o inverso, a terra perde calor mais rápido que o oceano, fazendo com que o fluxo de ar se inverta, siga em direção da terra para o mar.

De acordo com os dados do Balanço Energético Nacional, BEN (2021) a energia eólica corresponde a 8,8% da matriz elétrica brasileira. Constantemente em uma crescente, a energia eólica tem 17,75 GW de potência instalada, de acordo com o portal ABEEólica, já colaborando de forma direta na matriz elétrica nacional e com fortes tendências para continuar aumentando. A Figura 5 discrimina a participação de cada fonte energética no cenário atual brasileiro, onde está destacado em vermelho a porcentagem referente a contribuição da energia eólica.

Figura 5: Matriz elétrica brasileira 2021



Fonte: Adaptado de Balanço Energético Nacional (2021).

Em um estudo elaborado pela ABEEólica (Associação Brasileira de Energia Eólica), o Brasil manteve-se na sétima posição no Ranking Mundial de capacidade eólica acumulada. Na Tabela 2 são expostos os países pioneiros, bem como a sua respectiva potência acumulada em MW.

Tabela 2: Ranking de países por potência acumulada 2020

País	MW
China	278.324
EUA	122.275
Alemanha	55.122
Índia	38.625
Espanha	27.238

França	17.946
Brasil	17.750
Reino Unido	13.731
Canadá	13.578
Itália	10.543

Fonte: Adaptado de ABEEólica (2020).

Em contrapartida, como pode ser visto na Tabela 3, quando se contabiliza a capacidade instalada no ano, o Brasil avança para o terceiro lugar com 2.297 MW.

Tabela 3: Ranking de países por capacidade instalada 2020

País	MW
China	48.940
EUA	16.913
Brasil	2.297
Noruega	1.532
Alemanha	1.431
Espanha	1.400
França	1.317
Turquia	1.224
Índia	1.119
Austrália	1.097

Fonte: Adaptado de ABEEólica (2020).

4 DADOS METEOROLÓGICOS

Os bancos de dados meteorológicos são planejados para receber, armazenar, processar, e disponibilizar dados e informações das diversas variáveis meteorológicas (ex. precipitação pluviométrica, temperatura do ar, umidade relativa do ar ou radiação) (VIANNA, 2017). Os dados obtidos são provenientes ou de leituras ou registros contínuos dos instrumentos, que variam de acordo com o parâmetro de análise (direção e velocidade dos ventos, precipitação, pressão atmosférica e temperatura).

Existem dois tipos de Estações Meteorológicas de Superfície: Convencionais e Automáticas. Uma Estação Meteorológica Convencional (EMC) exige a presença diária de um pesquisador para a coleta dos dados (GALINA & VERONA, 2004). Estas estações dividem-se de acordo com a quantidade de parâmetros observados, as de primeira classe coletam todos os elementos climáticos, de segunda classe não realizam as medidas de pressão atmosférica, radiação solar e vento, por fim, as de terceira classe medem temperatura máxima e mínima e índices pluviométricos.

A Estação Meteorológica Automática (EMA) coleta seus dados de forma totalmente automatizada. O *Datalogger*, um sistema de aquisição de dados, recebe sinais elétricos emitidos pelos sensores, processando e armazenando os dados para consulta futura. A principal vantagem desse tipo de estação, se trata exatamente do registro contínuo sem necessitar da presença diária de algum observador. A Figura 6 ilustra uma estação meteorológica automática, composta por anemômetro, piranômetro, sensor de temperatura e umidade e pluviômetro.

Figura 6: Estação Meteorológica Automática.



Fonte: Mundo Clima (2021).

No Brasil, o órgão responsável pelo estabelecimento, coordenação e operação das estações meteorológicas é o Instituto Nacional de Meteorologia (INMET). Com sede em Brasília, é de sua função administrar mais de 400 estações meteorológicas de superfície e 500 EMA's, distribuídas em território brasileiro (VIANELLO, 2011).

A rede do INMET é a maior rede de estações meteorológicas no Brasil, mas não é a única existente, outros órgãos operacionais possuem redes de observações, como Força Aérea Brasileira, Marinha do Brasil, Secretaria de Estado, Instituições de Ensino e Pesquisa, Empresas Públicas Para-Estatais e Privadas (TUBELLIS e NASCIMENTO, 1980).

Os dados utilizados para a realização deste trabalho foram coletados no banco de dados disponibilizado pelo INMET (<https://inmet.gov.br>), referentes à estação meteorológica de Fortaleza, no estado do Ceará. As informações foram devidamente analisadas para verificar qual período de dados era mais consistente. Após isso, foram pré-processados e organizados por médias diárias, os modelos treinados e validados

utilizando o software MATLAB 2020. Os dados de vento da estação meteorológica foram utilizados para a elaboração de modelos preditivos de velocidade do vento, utilizando métodos lineares e não-lineares.

5 RESULTADOS E DISCUSSÃO

Os dados utilizados foram retirados do banco de dados do INMET, referentes a uma estação meteorológica do município de Fortaleza/CE, onde foram tratados de maneira que apenas os dados de interesse do estudo fossem importados para o software MATLAB. Por conseguinte, foram divididos de acordo com o período amostral referente ao mês que estaria sendo posto em ensaio.


Os meses escolhidos foram os de agosto, setembro e outubro, com os intervalos de séries históricas utilizados de 15, 20 e 25 dias. Foi desenvolvido um algoritmo que abrange desde a importação dos dados, onde nos modelos propostos foi atribuída a divisão dos dados entre treinamento e validação, escolha do método linear ou não linear pelo qual as informações seriam processadas e plotagem da figura, onde é comparada os dados reais com os dados obtidos na previsão. Os resultados obtidos nas previsões variam de acordo com o período, método utilizado e em qual ordem ele foi submetido. As ordens atribuídas a cada modelo referem-se a quantidade de neurônios na primeira e segunda camadas ocultas, bem como na camada de saída

Cada método utilizado possui uma função específica no MATLAB, possibilitando que o conjunto de dados seja aplicado a estrutura linear de cada processo, podendo assim identificar qual se adequa melhor ao período amostral estipulado e resulta em uma previsão mais próxima aos dados reais.

Os dados apurados foram dos meses de agosto, setembro e outubro do ano de 2018. Os períodos amostrais de velocidade do vento foram de 15, 20 e 25 dias para fazer a estimação utilizando os modelos paramétricos lineares BJ e OE e o modelo não linear NARX. Em média, 70% dos dados foram utilizados para o treinamento e o remanescente para validação.

Na Figura 7 é exposto um gráfico onde está representada a velocidade do vento no eixo y pelos dias que estão no eixo x, um exemplo da divisão dos dados entre treinamento e validação. A amostra em questão é referente ao mês de setembro com o intervalo de 25 dias, a linha azul representa a parcela dos dados utilizados como treinamento e a laranja validação.

Figura 7: Divisão dos dados entre treinamento e validação



Fonte: Próprio autor (2021)

Após diversos ensaios com variadas ordens, para cada mês foi apurado qual o conjunto de amostras que apresentaram um resultado mais fidedigno com a realidade. Através do algoritmo desenvolvido no MATLAB, a ferramenta retorna um gráfico comparativo entre o resultado do modelo e os dados reais. Na legenda, uma porcentagem que representa o grau de proximidade do sistema de previsão. A seguir, esses gráficos são apresentados de acordo com os melhores resultados de cada mês.

5.1 Modelo OE

De acordo com a equação que representa o modelo OE, evidenciada no Capítulo 2, foram feitos diversos testes afim de determinar qual ordem do modelo seria mais eficiente para o horizonte antes mencionado. Os dois melhores resultados dentre todas as ordens testadas para cada intervalo amostral dos respectivos meses são apresentados na Tabela 4.

Tabela 4: Resultados modelo OE.

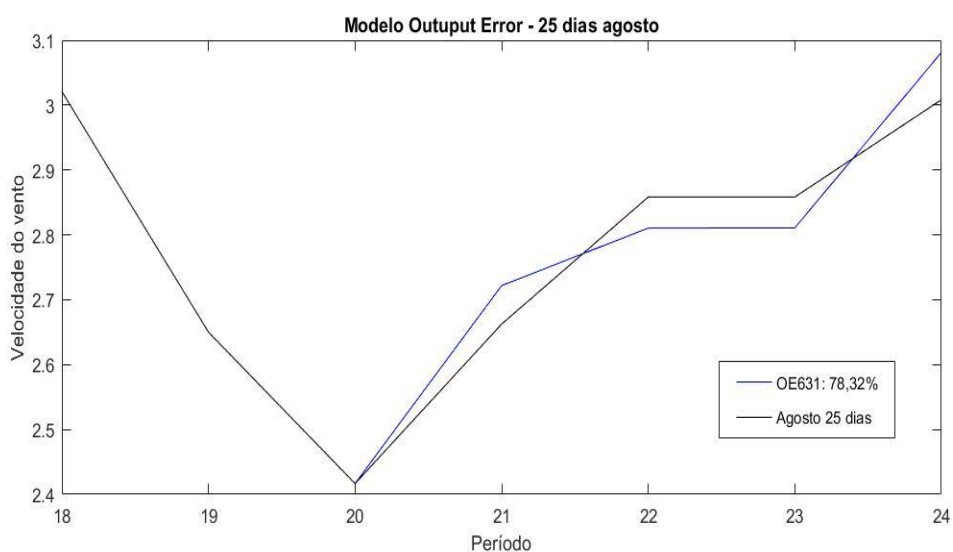
Mês: Agosto - modelo OE			Mês: Setembro - modelo OE			Mês: Outubro - modelo OE		
Intervalo	Ordem	FIT(%)	Intervalo	Ordem	FIT(%)	Intervalo	Ordem	FIT(%)
15 dias	121	23,48	15 dias	134	81,50	15 dias	122	89,25
	311	39,60		135	84,46		131	97,80
20 dias	511	25,04	20 dias	145	65,36	20 dias	421	97,24
	412	13,05		141	64,83		411	90,44

25 dias	631	78,32	25 dias	651	87,91	25 dias	622	90,59
	641	59,52		611	71,11		613	81,73

Fonte: Elaborado pelo autor (2021).

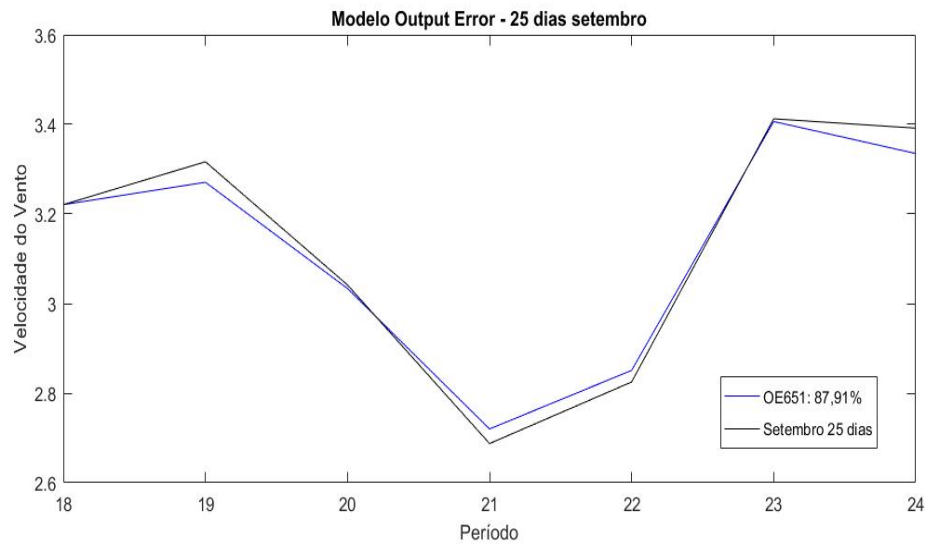
Nas figuras 8, 9, e 10 é apontado o gráfico com o melhor resultado obtido pelo modelo OE entre os intervalos de 15, 20 e 25 dias de cada mês, e sua porcentagem de acurácia. Nestas, observa-se a comparação entre as curvas referentes ao período de validação e a previsão desenvolvida pelo método, retratando a velocidade do vento para cada dia em específico.

Figura 8: Resultado modelo OE de agosto 25 dias



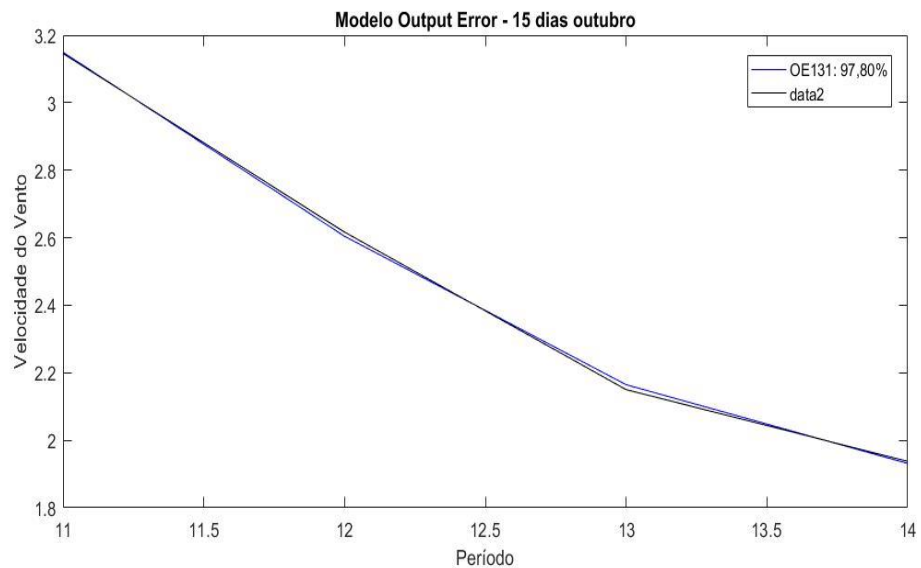
Fonte: Próprio autor (2021).

Figura 9: Resultado modelo OE de setembro 25 dias



Fonte: Próprio autor (2021).

Figura 10: Resultado modelo OE de outubro 15 dias



Fonte: Próprio autor (2021).

O melhor modelo obtido foi referente ao mês de outubro, com o intervalo de 15 dias, através da ordem 131 apresentando uma acurácia de 97,80% e um MSE, *Mean Square Error*, de 0,01248. Os polinômios que descrevem o modelo são expostos na seção 2.1.2. Pela ferramenta MATLAB foi possível identificar os polinômios $B(q)$ e $F(q)$.

$$B(q) = 0,008712z^{-1} \quad 5.1$$

$$F(q) = 1 - 2,389z^{-1} + 2,025z^{-2} + 0,607z^{-3} \quad 5.2$$

Substituindo os parâmetros acima na Equação 2.9, tem-se a equação que relaciona a saída e entrada no modelo:

$$y(k) = \left[\frac{0,008712z^{-1}}{1 - 2,389z^{-1} + 2,025z^{-2} + 0,607z^{-3}} \right] u(k) + v(k) \quad 5.3$$

5.2 Modelo BJ

Utilizando o Modelo BJ (*Box-Jenkins*), sua equação pode ser vista na Seção 2.2.1, várias combinações de ordem foram testadas no intuito de buscar o melhor desempenho. Os intervalos testados foram de 15, 20 e 25 dias, dos meses de agosto, setembro e outubro. Os melhores valores de acurácia foram registrados na Tabela 5, onde foi evidenciada a relação entre o mês, intervalo de dias e as duas melhores ordens relacionadas com sua acurácia (FIT).

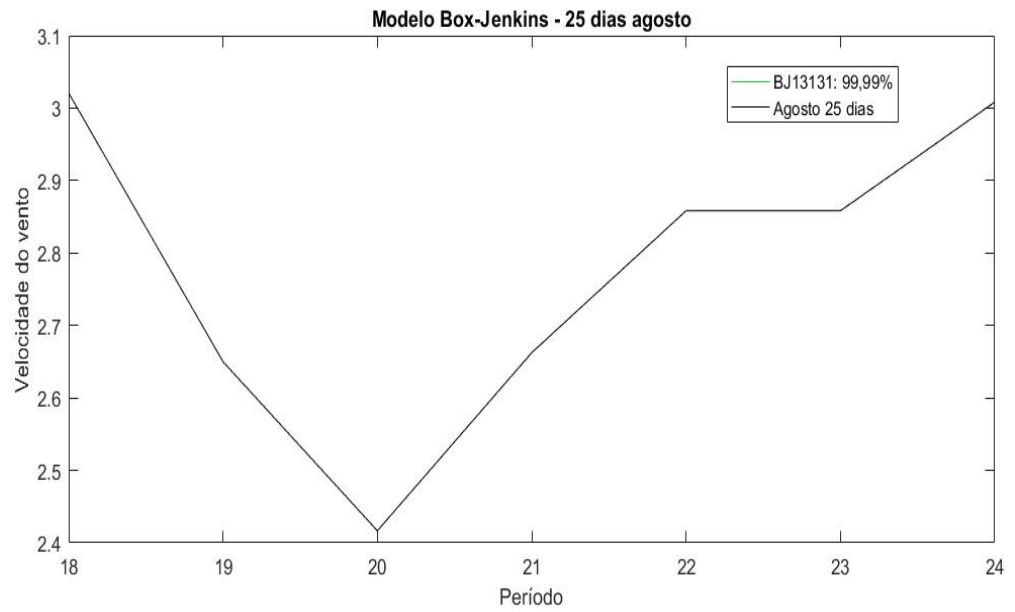
Tabela 5: Resultados modelo BJ

Mês: Agosto - modelo BJ			Mês: Setembro - modelo BJ			Mês: Outubro - modelo BJ		
Intervalo	Ordem	FIT(%)	Intervalo	Ordem	FIT(%)	Intervalo	Ordem	FIT(%)
15 dias	12112	89,65	15 dias	11122	81,85	15 dias	21121	99,77
	12111	60,62		21121	58,37		11211	95,31
20 dias	32121	97,07	20 dias	12121	97,44	20 dias	21211	96,34
	12121	82,56		12122	96,16		22211	95,89
25 dias	13131	99,99	25 dias	22331	94,73	25 dias	13232	97,62
	31311	99,74		21331	93,78		13132	96,38

Fonte: Próprio autor (2021).

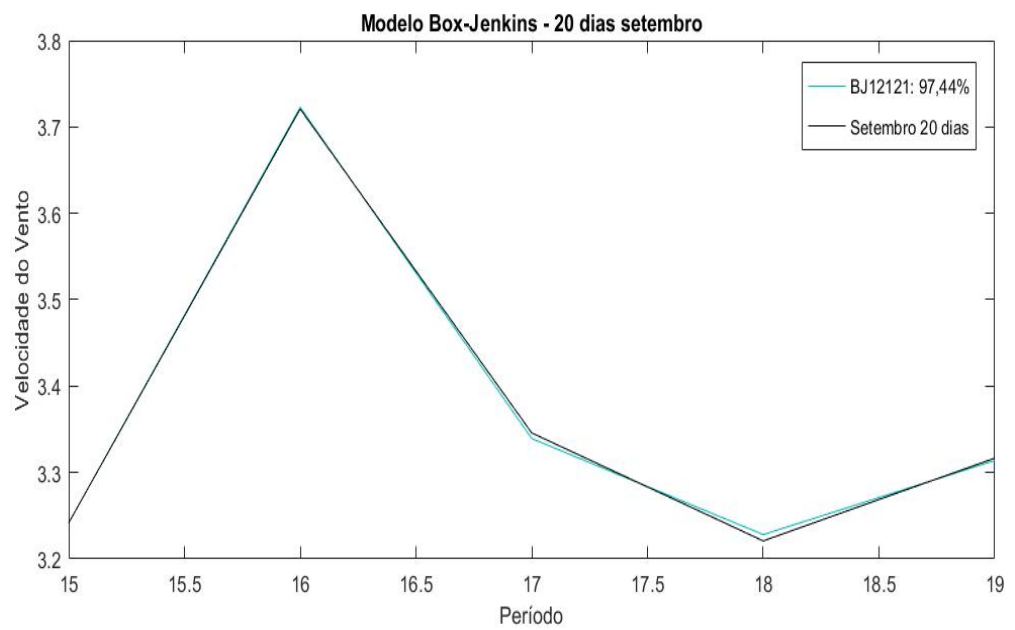
Nas Figuras 11, 12, e 13 estão retratadas as representações gráficas que dispuseram a maior previsão, obtidas pelo modelo BJ aplicado para cada mês. Qualquer ordem resulta em um valor de acurácia próprio, nas imagens será retratada a recorrência relacionada a ordem específica, associando a velocidade do vento correspondente ao dia específico.

Figura 11: Resultado modelo BJ de agosto 25 dias



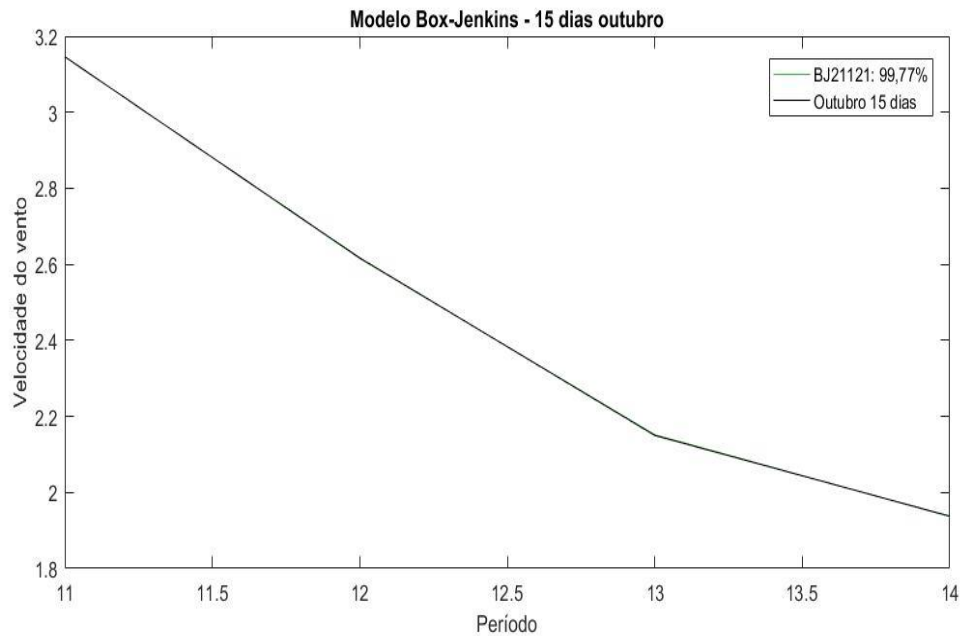
Fonte: Próprio autor (2021).

Figura 12: Resultado modelo BJ de setembro 20 dias



Fonte: Próprio autor (2021).

Figura 13: Resultado modelo BJ de outubro 15 dias



Fonte: Próprio autor (2021).

O intervalo de 25 dias de agosto com ordem 13131 apresentou a maior semelhança com os dados reais, obtendo uma acurácia de 99,99% e MSE de 0,03647. Os polinômios que compõem o modelo BJ podem ser vistos na Seção 2.1.1.

Utilizando a ferramenta MATLAB, através de linhas de códigos criadas dentro do software, encontra-se os seguintes valores para os polinômios:

$$B(q) = 0,0211z^{-1} \quad 5.4$$

$$C(q) = 1 - 0,9099z^{-1} + 0,5803z^{-2} - 0,4045z^{-3} \quad 5.5$$

$$D(q) = 1 - 0,6685z^{-1} \quad 5.6$$

$$F(q) = 1 - 0,7858z^{-1} - 0,8773z^{-2} + 0,7405z^{-3} \quad 5.7$$

Substituindo os parâmetros acima na Equação 2.7, tem-se a equação que relaciona a saída e entrada no modelo:

$$y(k) = \left[\frac{0,0211z^{-1}}{1 - 0,7858z^{-1} - 0,8773z^{-2} + 0,7405z^{-3}} \right] u(k) + \left[\frac{1 - 0,9099z^{-1} + 0,5803z^{-2} - 0,4045z^{-3}}{1 - 0,6685z^{-1}} \right] e(k) \quad 5.8$$

5.3 Modelo NARX

Para o modelo NARX, *Nonlinear AutoRegressive model with exogenous inputs*, testou-se várias ordens para identificar qual melhor iria se assimilar com os dados reais. Na tabela 6 a seguir, expõe-se os dois melhores resultados obtidos para os horizontes temporais de cada mês.

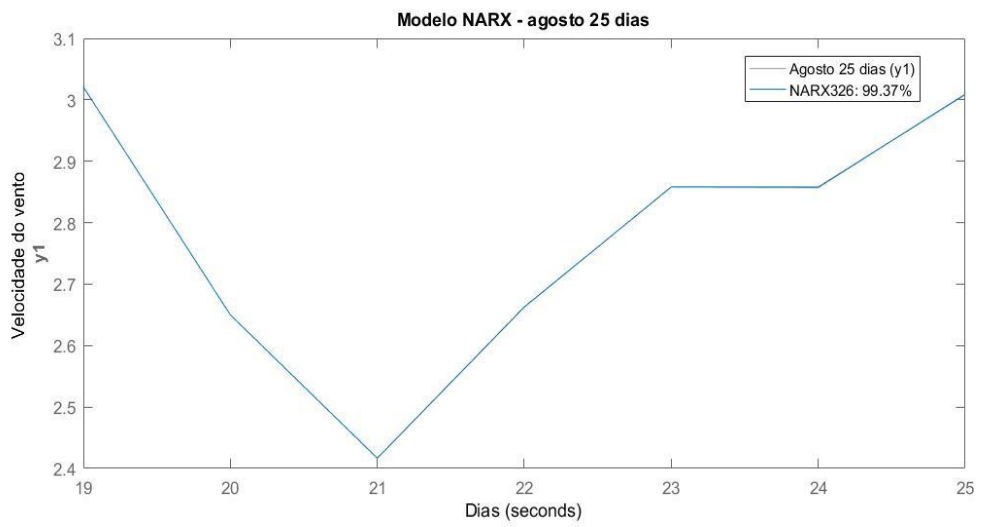
Tabela 6: Resultados Modelo NARX

Mês: Agosto - modelo NARX			Mês: Setembro - modelo NARX			Mês: Outubro - modelo NARX		
Intervalo	Ordem	FIT(%)	Intervalo	Ordem	FIT(%)	Intervalo	Ordem	FIT(%)
15 dias	223	99,60	15 dias	423	95,89	15 dias	323	98,82
	123	99,98		323	99,19		241	99,57
20 dias	342	99,81	20 dias	521	99,49	20 dias	513	99,70
	341	80,20		212	64,12		414	79,94
25 dias	326	99,37	25 dias	144	99,95	25 dias	244	99,88
	325	75,51		152	76,17		123	49,05

Fonte: Próprio autor (2021).

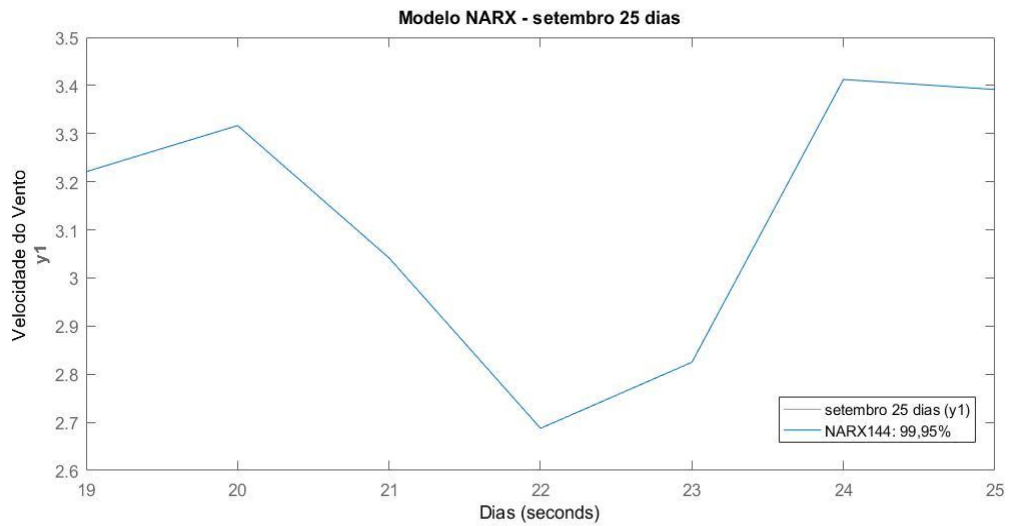
Nas figuras 14, 15 e 16 são retratadas as representações gráficas relacionando o valor da velocidade do vento ao respectivo dia, comparando o resultado da previsão com os dados de validação.

Figura 14: Resultado modelo NARX de agosto 25 dias




Fonte: Próprio autor (2021).

Figura 15: Resultado modelo NARX de setembro 25 dias



Fonte: Próprio autor (2021).

Figura 16: Resultado modelo NARX de outubro 25 dias



Fonte: Próprio autor (2021).

O mês de setembro com o intervalo de 25 dias foi o que obteve a maior acurácia, de 99,95% e MSE de $3,675e^{-08}$. Os polinômios que descrevem o método NARX podem ser vistos na Seção 2.2.1. Os regressores não lineares utilizados pelo MATLAB foram:

$$y1(t - 1) \quad 5.9$$

$$u1(t - 4) \quad 5.10$$

$$u1(t - 5) \quad 5.11$$

$$u1(t - 6) \quad 5.12$$

$$u1(t - 7) \quad 5.13$$

6 CONCLUSÃO

Este trabalho teve como propósito aplicar técnicas de identificação de sistemas, para previsão de vento utilizando o software MATLAB. Pela velocidade do vento impactar diretamente na produção de eletricidade oriunda da fonte eólica, a previsão desta variável possibilita um melhor planejamento para uma manutenção em um parque eólico, contribuindo na escolha de um período onde irá ocorrer uma menor geração e conseqüentemente uma parada técnica mais eficiente.

De mesmo modo, a previsão destes dados pode auxiliar tanto na estimação do potencial eólico de um local quanto na escolha da melhor data em que uma manutenção de um sistema de energia eólico iria causar menos perdas. Nesse estudo foram utilizadas 2 estruturas de modelos paramétricos lineares: Output Error e Box-Jenkins, como também uma estrutura não linear: NARX, *Nonlinear AutoRegressive model with exogenous inputs*.

O modelo linear *Box-Jenkins* apresentou, dentre todos os períodos amostrais, o melhor resultado de previsão, com uma acurácia de 99,99% e MSE de 0,03647 em comparação ao método não linear NARX e linear OE, que obtiveram acurácias de 99,95% e MSE de $3,675e^{-08}$ e 97,80% e um MSE de 0,01248 respectivamente.

Pelos resultados obtidos, conclui-se que os modelos de previsão utilizando métodos lineares e não lineares podem ser bastante precisos quando se tem a disposição um banco de dados vasto, consistente e bem organizado sendo aplicado a um método onde é definido a ordem e as partes de experimento e validação.

Recomendações para trabalhos futuros:

- Aplicar os dados previstos dos ventos para estimar a potencia gerada;
- Utilizar os dados da estação meteorológica da unidade campus do Auroras, Unilab – Redenção como banco de dados;
- Utilizar outros métodos lineares e não lineares para análise.

REFERÊNCIAS

AGUIRRE, Luis Antonio. **Introdução à identificação de sistemas—Técnicas lineares e não-lineares aplicadas a sistemas reais**. Editora UFMG, 2004.

ALVES, Antônio César Baleeiro. **INTRODUÇÃO AO PROGRAMA " MATLAB" COM APLICAÇÕES**, 2007.

Balanço Energético Nacional 2020 – Relatório Síntese. **Balanço Energético Nacional - BEN**, Rio de Janeiro, 20 de nov. de 2021. Disponível em: <
https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-479/topico-521/Relato%CC%81rio%20Si%CC%81ntese%20BEN%202020-ab%202019_Final.pdf >.

ANNUAL Wind Energy Wind Report 2020, **ABEEólica, 2020**. Disponível em: <
http://abeeolica.org.br/wp-content/uploads/2021/07/EN_Boletim-Anual-de-Gera%C3%A7%C3%A3o_2020_compressed.pdf >. Acesso em 20 de dez. de 2021.

CAJUEIRO, Emanuel Benício de Almeida. **Inferindo posição e carga de haste polida de bombeio mecânico a partir de corrente de saída de inversor de frequência**. 2012.

COELHO, MC d S. **Modelos de Hammerstein e de Wiener: conexões com modelos narx e sua aplicação em identificação de sistemas não-lineares**. 2002. Tese de Doutorado. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil.

DA SILVA, SILVANIA MARIA SANTOS. **Estudo dos parâmetros aerodinâmicos para melhoria da previsão do vento no estado de Alagoas**. 2018.

Eólica: Energia para um futuro inovador. **ABEEólica**, São Paulo, 20 de nov. de 2021. Disponível em: < <http://abeeolica.org.br/energia-eolica-o-setor/> >.

EPE – Empresa de Pesquisa Energética. **Anuário Estatístico de Energia Elétrica 2021**. Brasília. 2021.

FREITAS, Adriel de Oliveira. **Modelagem matemática da curva de descarga da bateria de um quadrirotor rolling spider utilizando a teoria de identificação de sistemas**. 2019.

GALINA, Márcia Helena; VERONA, Juliana Augusta. **Fontes de observações meteorológicas no estado de São Paulo**. Estudos Geográficos: Revista Eletrônica de Geografia, v. 2, n. 1, p. 107-118, 2004.

GOMES, Jorge Luis. **Previsão de vento e precipitação em altíssima resolução em região de topografia complexa**. 2017.

GOUVEIA, Hugo Tavares Vieira. **Previsão de ventos e geração eólica do sistema NE: analisando diversos sítios e buscando a melhor modelagem através da inteligência artificial**. 2011. Dissertação de Mestrado. Universidade Federal de Pernambuco.

HAYKIN, Simon. **Redes Neurais Princípios e prática**. Livro 2ª ed. Porto Alegre: Bookman, 2008.

HIRUMA, Felipe Shogo. **Previsão da geração de energia eólica com Redes Neurais Artificiais**. 2017.

HUANG, Jin et al. Using NARX neural network based load prediction to improve scheduling decision in grid environments. In: **Third International Conference on Natural Computation (ICNC 2007)**. IEEE, 2007. p. 718-724.

JENSEN, U.S.; PELGRUM, E.; MADSEN, H. “**The Development of a Forecasting Model for the Prediction of Wind Power Production to be Used in Central Dispatch Centres**”. Proceedings of the EWEC '94, Thessaloniki, p. 353-356, 1994.

JIANG, Y.; SONG, Z.; KUSIAK, A. **Previsão da velocidade do vento de curtíssimo prazo com modelo de quebra estrutural Bayesiana**. Energia Renovável, v. 50, p. 637-647, 2013.

MENEZES JÚNIOR, José Maria Pires de. **Redes neurais dinâmicas para predição e modelagem não-linear de séries temporais**. 2006.

KUMPATI, S. Narendra et al. **Identification and control of dynamical systems using neural networks**. IEEE Transactions on neural networks, v. 1, n. 1, p. 4-27, 1990.

L. Ljung, **System Identification: Theory for the User, 2nd ed. New Jersey: Prentice Hall PTR**, 1999.

LYRA, Roberto Fernando Fonseca et al. **Prognóstico da velocidade do vento utilizando o modelo WRF na região central de Alagoas**. Ciência e Natura, v. 38, p. 447-451, 2016.

MACHADO, Marlon Vinícius. **Modelagem matemática do tempo de vida de baterias utilizando modelos autorregressivos**. 2014.

MENEZES JÚNIOR, José Maria Pires de. **Redes neurais dinâmicas para predição e modelagem não-linear de séries temporais**. 2006.

MENEZES, J. M. P.; BARRETO, G. A. **Redes neurais dinâmicas para predição e modelagem não-linear de séries temporais**. 2006. Tese de Doutorado. Dissertação (Mestrado em Engenharia de Teleinformática)–Programa de Pós-Graduação em Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza.

MOLION, Luiz Carlos Baldicero; BERNARDO, S. de O. **Uma revisão da dinâmica das chuvas no nordeste brasileiro**. Revista Brasileira de Meteorologia, v. 17, n. 1, p. 1-10, 2002.

Mundo Clima. **Estação Meteorológica Automática Mercury**. Disponível em <<https://www.mundoclima.com.br/produtos/estacao-meteorologica-automaticamercury/>>. Acesso em: 22 de nov. de 2021.

NARENDRA, K.S.; PARTHASARATHY, K. **Identification and control of dynamical systems using neural networks**. IEEE Transactions on Neural Networks, v 1, n. 1, p. 4-27, 1990

OLIVEIRA, Josinaldo Bezerra de. **Sistemas inteligentes e wavelets para previsão de vento e geração eólica**. 2008. Dissertação de Mestrado. Universidade Federal de Pernambuco.

OST, Augusto. **Modelagem matemática do conjunto ESC-motor-hélice de um VANT utilizando identificação de sistemas**. 2015.

ROMIO, Leugim Corteze et al. **Aplicação de identificação de sistemas no tempo de vida de baterias de dispositivos móveis**. 2012.

SANTOS, André Alves Portela et al. **Previsão não-linear da taxa de câmbio real/dólar utilizando redes neurais e sistemas nebulosos**. 2005.

SANTOS, Iwldson Guilherme Da Silva. **Previsão da velocidade do vento na escala do parque eólico utilizando o modelo wrf e rede neural artificial**. 2019.

SATHYAJITH, Mathew. **Wind energy: fundamentals, resource analysis and economics**. Springer Science & Business Media, 2014.

SFETSOS, A. **A novel approach for the forecasting of mean hourly wind speed time series**. Renewable energy, v. 27, n. 2, p. 163-174, 2002.

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, IN da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber, v. 23, n. 5, p. 33-111, 2010.

SILVA, S. M. S. **Avaliação do desempenho do Modelo WRF para Prognóstico do vento na Região Central de Alagoas - Craíbas**. 45 f. Trabalho de Conclusão de Curso (Bacharelado em Meteorologia) – Universidade Federal de Alagoas (UFAL), Maceió, 2016.

SOMAN, Saurabh S. et al. **Uma revisão dos métodos de previsão de energia eólica e velocidade do vento com diferentes horizontes de tempo**. In: América do Norte Symposium. 2010. p. 1-8.

TUBELIS, A., NASCIMENTO, F.J.L., Estrutura Meteorológica In: **Meteorologia Descritiva. Fundamentos e Aplicações Brasileiras**, 1º Edição, São Paulo: NOBEL, 1980, pp. 343-374.

VIANELLO, Rubens Leite. A estação meteorológica e seu observador. **Instituto Nacional de Meteorologia**, Brasília, 10 de mai. de 2011. Disponível em: < <https://portal.inmet.gov.br/uploads/publicacoesDigitais/aestacaometeorologicaeseuobservador.pdf> > Acesso em: 25 de nov. de 2021.

VIANNA, Luiz Fernando de Novaes et al. **Bancos de dados meteorológicos: Análise dos metadados das Estações Meteorológicas no Estado de Santa Catarina, Brasil**. Revista Brasileira de Meteorologia, v. 32, p. 53-64, 2017.