



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA MECÂNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

TIAGO DE OLIVEIRA NOGUEIRA

**ANÁLISE DE DESBALANCEAMENTO DE TURBINA EÓLICA EM ESCALA
UTILIZANDO REDE NEURAL DE BASE RADIAL COMO CLASSIFICADOR**

FORTALEZA

2021

TIAGO DE OLIVEIRA NOGUEIRA

ANÁLISE DE DESBALANCEAMENTO DE TURBINA EÓLICA EM ESCALA
UTILIZANDO REDE NEURAL DE BASE RADIAL COMO CLASSIFICADOR

Dissertação apresentada ao Programa de Pós- Graduação em Engenharia Mecânica da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre em Engenharia Mecânica. Área de concentração: Processos, Equipamentos e Sistemas para Energias Renováveis. Orientador: Prof^a. Dr^a. Carla Freitas de Andrade.

Coorientador: Elineudo Pinho de Moura

FORTALEZA

2021

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

N716a Nogueira, Tiago de Oliveira.
Análise de desbalanceamento de turbina eólica em escala utilizando rede neural de base radial como classificador / Tiago de Oliveira Nogueira. – 2021.
90 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Mecânica, Fortaleza, 2021.
Orientação: Profª. Dra. Carla Freitas de Andrade.
Coorientação: Prof. Dr. Elineudo Pinho de Moura.

1. Análise de vibração. 2. DFA. 3. RNBR. 4. Turbina eólica. I. Título.

CDD 620.1

TIAGO DE OLIVEIRA NOGUEIRA

ANÁLISE DE DESBALANCEAMENTO DE TURBINA EÓLICA EM ESCALA
UTILIZANDO REDE NEURAL DE BASE RADIAL COMO CLASSIFICADOR

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica, do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial para a obtenção do Título de Mestre em Engenharia Mecânica. Área de Concentração: Processos, Equipamentos e Sistemas para Energias Renováveis.

Aprovada em 08/07/2021

BANCA EXAMINADORA

Prof.^a Dra. Carla Freitas de Andrade (Orientadora)
Universidade Federal do Ceará (UFC)

Prof. Dr. Elineudo Pinho de Moura (Coorientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Paulo Alexandre Costa Rocha
Universidade Federal do Ceará (UFC)

Prof. Dr. Francisco Olimpio Moura Carneiro
Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)

A Deus. Aos meus pais, irmãos e noiva.

AGRADECIMENTOS

À CAPES, pelo apoio financeiro com a manutenção da bolsa de auxílio.

Ao Prof.^a Dra. Carla Freitas de Andrade, pela excelente orientação e ao Prof. Dr. Elineudo Pinho de Moura pela coorientação.

Aos professores participantes da banca examinadora Paulo Alexandre Costa Rocha e Francisco Olimpio Moura Carneiro pelo tempo, pelas valiosas colaborações e sugestões.

Aos colegas da turma de mestrado, pelas reflexões, críticas e sugestões recebidas.

“O vento sopra, só Ele sabe para onde vai.”

Aline Barros

RESUMO

Devido ao aumento da preocupação com questões ambientais, métodos sustentáveis de produção energética têm ganhado cada vez mais espaço, e com isso, a melhoria da eficiência dessas tecnologias, sobretudo a eólica – devido ao seu poder de produção e baixo custo de produção – é de suma importância. Esta presente dissertação realiza um estudo dos sinais de vibração extraídos de uma turbina eólica em escala. Massas de 0,5 g, 1,0 g e 1,5 g foram adicionadas às pontas de uma e duas pás, simulando possíveis problemas, como erosão ou acúmulo de gelo, além da condição normal, onde as três pás e o sistema estavam balanceados. O sistema funcionou em três rotações diferentes: 900 rpm, 1200 rpm e 1500 rpm. Usou-se a análise de flutuações destendenciadas (DFA) para o pré-processamento dos sinais originais. Em seguida, os vetores foram classificados pelo modelo de Rede Neural de Base radial, uma técnica de reconhecimento de padrões com treinamento supervisionado. O classificador alcançou um resultado de 98,83%, 98,15% e 96,92%, para as rotações de 900 rpm, 1200 rpm e 1500 rpm, respectivamente, no reconhecimento dos padrões em estudo, sendo capaz de diferenciar, com índices maiores que 96%, as condições normais de operação das condições de desbalanceamentos definidas. Além disso, comparado a outros métodos já utilizados para o mesmo fim, os resultados foram próximos, sendo inferior para 900 rpm, em 0,46%; superior em 4%, para 1200 rpm; e inferior em 1% para 1500 rpm. Por fim, conclui-se a capacidade do classificador estudado na identificação de sinais desconhecidos, sendo importante na identificação de possíveis defeitos que possam surgir nas pás de uma turbina eólica, a partir dos resultados obtidos são muito promissores e podem dar contribuições relevantes no desenvolvimento de um sistema de detecção e classificação de defeitos em pás de aerogeradores.

Palavras-chave: Análise de vibração. DFA. RNBR. Turbina eólica.

ABSTRACT

Due to the increased concern with environmental issues, sustainable methods of energy production have gained more and more space, and with this, the improvement in the efficiency of these technologies, especially wind power - due to its production power and low production cost - is of short importance. This present dissertation performs a study of the vibration signals extracted from a scaled wind turbine. Masses of 0.5 g, 1.0 g, and 1.5 g were added to the tips of one and two blades, simulating possible problems such as erosion or ice accumulation, in addition to the normal condition, where the three blades and the system were balanced. The system ran at three different speeds: 900 rpm, 1200 rpm, and 1500 rpm. Extended fluctuation analysis (DFA) was used for the pre-processing of the original signals. Then, the vectors were classified by the Radial Base Neural Network model, a pattern recognition technique with supervised training. The classifier achieved a result of 98.83%, 98.15%, and 96.92%, for the rotations of 900 rpm, 1200 rpm, and 1500 rpm, respectively, in the recognition of the patterns under study, being able to differentiate, with indices greater than 96%, the normal operating conditions of the defined imbalance conditions. Furthermore, compared to other methods already used for the same purpose, the results were similar, being lower for 900 rpm, at 0.46%; 4% higher for 1200 rpm; and lower by 1% for 1500 rpm. Finally, the capacity of the classifier studied in the identification of unknown signals is concluded, being important in the identification of possible defects that may arise in the blades of a wind turbine, from the results obtained are very promising and can make relevant contributions in the development of a system for the detection and classification of defects in wind turbine blades.

Keywords: Vibration analysis. DFA. RNBR. Wind turbine.

LISTA DE FIGURAS

Figura 1	- Fluxo de ar através de um disco de rotor	21
Figura 2	- Variação da curva de potência devido a várias espessuras de partículas de sujeira.....	24
Figura 3	- Rugosidades causadas por acúmulo de gelo	25
Figura 4	- Aplicação de DFA às oscilações neuronais. (a) Registro de sinal de EEG (b) sinal filtrado (c) DFA aplicado ao envelope de amplitude do sinal de ruído branco filtrado	30
Figura 5	- Principais componentes de um neurônio matemático teórico com função de ativação que possui limiar de ativação	34
Figura 6	- Ilustração gráfica de uma RNA	35
Figura 7	- Componentes básicos de uma RBFN	37
Figura 8	- Representação da grade criada pela variação de valores de hiperparâmetros no método Grid Search	39
Figura 9	- Bancada de testes	57
Figura 10	- Representação do posicionamento dos pesos adicionados em uma pá	58
Figura 11	- Representação do posicionamento dos pesos adicionados em duas pás	58
Figura 12	- Representação de pá sem adição de massa	59
Figura 13	- Representação de sinal de vibração normalizado em uma turbina eólica em escala com uma pá com adição de peso em rotação de 1200 rpm	60
Figura 14	- Representação de curva DFA gerada pelo sinal obtido na Figura 13	60
Figura 15	- Representação de matriz de confusão	63

LISTA DE TABELAS

Tabela 1 - Valores de α e suas relações	31
Tabela 2 - Relação das publicações no Brasil	43
Tabela 3 - Nomenclatura para as 3 classes utilizadas para a classificação	62
Tabela 4 - Nomenclatura para as 7 classes utilizadas para a classificação	63
Tabela 5 - Taxa média de acerto para 3 classes em diferentes rotações	65
Tabela 6 - Taxa média de acerto para 7 classes em diferentes rotações	66
Tabela 7 - Matriz de confusão gerada de vetores originais de três classes em 900 rpm ..	67
Tabela 8 - Matriz de confusão gerada de vetores originais de sete classes em 900 rpm .	68
Tabela 9 - Matriz de confusão gerada de vetores originais de três classes em 1200 rpm	68
Tabela 10 - Matriz de confusão gerada de vetores originais de sete classes em 1200 rpm	69
Tabela 11 - Matriz de confusão gerada de vetores originais de três classes em 1500 rpm	69
Tabela 12 - Matriz de confusão gerada de vetores originais de sete classes em 1500 rpm	70
Tabela 13 - Matriz de confusão gerada de vetores após DFA de três classes em 900 rpm	72
Tabela 14 - Matriz de confusão gerada de vetores após DFA de sete classes em 900 rpm	72
Tabela 15 - Matriz de confusão gerada de vetores após DFA de três classes em 1200 rpm	73
Tabela 16 - Matriz de confusão gerada de vetores após DFA de sete classes em 1200 rpm	73
Tabela 17 - Matriz de confusão gerada de vetores após DFA de três classes em 1500 rpm	74
Tabela 18 - Matriz de confusão gerada de vetores após DFA de sete classes em 1500 rpm	74
Tabela 19 - Comparação de valores médios da taxa de acerto para diferentes métodos para as 3 rotações de trabalho	77

LISTA DE GRÁFICOS

Gráfico 1	- Quantidade de publicações por ano encontrados na base Scopus, considerando as palavras chaves “Imbalance” e “wind turbine”	41
Gráfico 2	- Quantidade de publicações por instituições encontrados na base Scopus, considerando as palavras chaves “Imbalance” e “wind turbine”	42
Gráfico 3	- Quantidade de publicações por país encontrados na base Scopus, considerando as palavras chaves “Imbalance” e “wind turbine”	43
Gráfico 4	- Produção científica por instituições brasileiras relacionada ao tema pesquisado	45
Gráfico 5	- Quantidade de publicações por ano encontrados na base Scopus, considerando as palavras chaves chaves “wind turbine”, "neural network" e "radial basis"	46
Gráfico 6	- Quantidade de publicações por instituição encontrados na base Scopus, considerando as palavras chaves “wind turbine”, "neural network" e "radial basis"	47
Gráfico 7	- Quantidade de publicações por país encontrados na base Scopus, considerando as palavras chaves “wind turbine”, "neural network" e "radial basis"	47
Gráfico 8	- Quantidade de publicações por ano encontrados na base Scopus, considerando as palavras chaves chaves “wind turbine”, "blade" e "imbalance"	49
Gráfico 9	- Quantidade de publicações por instituição encontrados na base Scopus, considerando as palavras chaves chaves “wind turbine”, "blade" e "imbalance"	50
Gráfico 10	- Quantidade de publicações por país encontrados na base Scopus, considerando as palavras chaves chaves “wind turbine”, "blade" e "imbalance"	51
Gráfico 11	- Quantidade de publicações por ano encontrados na base Scopus, considerando as palavras chaves chaves “wind turbine” e “vibration”	52
Gráfico 12	- Quantidade de publicações por instituição encontrados na base Scopus, considerando as palavras chaves chaves “wind turbine” e “vibration”	53

Gráfico 13	- Quantidade de publicações por país encontrados na base Scopus, considerando as palavras chaves “wind turbine” e “vibration”	54
Gráfico 14	- Quantidade de publicações por país encontrados na base Scopus, considerando as palavras chaves “DFA” e “vibration”	55
Gráfico 15	- Quantidade de publicações por instituição encontrados na base Scopus, considerando as palavras chaves “DFA” e “vibration”	56
Gráfico 16	- Comparação das taxas médias de acerto antes de DFA, de cada rotação, para 3 e 7 classes	71
Gráfico 17	- Comparação das taxas médias de acerto pós DFA, de cada rotação, para 3 e 7 classes	75
Gráfico 18	- Comparação de resultados antes e após a utilização do método DFA	76
Gráfico 19	- Comparação de resultados de classificadores	78

LISTA DE ABREVIATURAS E SIGLAS

ANN	Rede Neural Artificial
CCATMD	Sistema de Amortecedor de Massa Ativo Conectado por Cabo
CG	Classificador Gaussiano
CM	Monitoramento de Condições
DFA	Análise de Flutuações Destendenciadas
EFL	Carregamento de Fadiga Equivalente
GPS	Processos Gaussianos
IAEE	Instituto Alemão de Energia Eólica
KLT	Transformada de Karhunen-Loève
LR	Regressão Logística
LSTM	Memória de Curto Prazo Longa
RBFN	Rede Neural de Base Radial
SHM	Monitoramento de Saúde Estrutural
SVM	Máquina de Vetor de Suporte
TEEH	Turbinas Eólicas de Eixo Horizontal
TMD	Amortecedor de Massa Sintonizado
WTB	Pá de Turbinas Eólicas

LISTA DE SÍMBOLOS

A	Área Varrida
$f(x)$	Camada de Saída
μ	Centro Específico
N	Comprimento da Série
ρ	Densidade do Ar
D	Diâmetro do Rotor
E	Energia Cinética
α	Expoente de Escala
φ	Função de Ativação
M	Massa
K	Quantidade de Neurônios da Rede
w	Peso da Sinapse
r	Raio da Função Gaussiana
y_k	Saída do Neurônio
y_i	Série Acumulada
x_i	Sinal de Vibração
x_m	Valores de Entrada
V	Velocidade
\mathbf{x}	Vetor de Entrada

SUMÁRIO

1	INTRODUÇÃO	15
2	JUSTIFICATIVA	17
3	OBJETIVOS	18
3.1	Objetivos específicos	18
4	FUNDAMENTAÇÃO TEÓRICA	19
4.1	Classificação dos aerogeradores e seus componentes	19
4.2	Energia cinética do vento.....	20
4.3	Teoria da manutenção e adversidades em aerogeradores	22
4.4	Análise de Vibração	25
4.4.1	<i>Método de identificação de afinidade em série temporal (DFA)</i>	27
4.5	Aprendizado de máquina e análise de reconhecimento de padrões	31
4.5.1	<i>Redes Neurais Artificiais (RNA)</i>	34
4.5.2	<i>Redes Neurais de Base Radial (RNBR)</i>	37
4.5.3	<i>Otimização de hiperparâmetros (Grid Search)</i>	38
5	ESTUDO BIBLIOGRÁFICO	40
5.1	Publicações envolvendo desbalanceamento de turbinas eólicas	40
5.2	Publicações envolvendo turbinas eólicas e rede neural de base radial	45
5.3	Publicações envolvendo turbinas eólicas, desbalanceamento e pás eólicas	48
5.4	Pesquisas acadêmicas envolvendo turbinas eólicas e vibração	51
5.5	Pesquisas acadêmicas envolvendo DFA e vibração	54
6	METODOLOGIA	57
6.1	Processamento dos sinais de vibração	59
6.2	Classificação dos sinais	62
6.3	Sinais originais x sinais após DFA	64
7	RESULTADOS E DISCUSSÃO	64
7.1	Taxas de acerto para 3 e 7 classes de desbalanceamento (sinais originais)	67
7.2	Taxas de acerto para 3 e 7 classes (após DFA)	71
8	CONCLUSÃO	79
	REFERÊNCIAS	81

1 INTRODUÇÃO

Ao longo dos anos, a preocupação acerca do meio ambiente vem aumentando cada vez mais devido às altas taxas de emissões de poluentes, aquecimento global e desaparecimento de recursos naturais usados para a geração de energia elétrica, como o carvão mineral, petróleo e gás natural.

Uma das fontes renováveis é a eólica, por isso é importante que haja cada vez mais estudos acerca dessa tecnologia, a fim de garantir melhores resultados de eficiência para as turbinas eólicas.

Embora uma turbina eólica possa apresentar problemas em diversos componentes, os mais comuns são nas pás, assim deve-se ter mais atenção nos efeitos mecânicos que as pás sofrem pela ação do vento a fim de evitar fadigas, tensões excessivas, instabilidade e ruptura (Mishnaevsky, 2019).

Com o avanço das pesquisas, a análise de vibração pode ser realizada por processamento de sinal, como em De Moura *et al.* (2016). Um dos pontos mais importantes em relação às turbinas eólicas é o efeito negativo que as vibrações causam no seu desempenho, o que gerou um olhar mais atento dos pesquisadores em relação a esse fato.

B. Fitzgerald *et al.* (2014) por exemplo, propuseram um sistema de amortecedor de massa ativo conectado por cabo (CCATMD) para a mitigação da vibração da pá e viu que o uso do novo esquema de controle ativo proposto reduziu significativamente a vibração no plano de pás grandes e flexíveis de turbinas eólicas.

Sareen *et al.* (2014) mostraram a ação da erosão nas pás enquanto Sagol *et al.* (2013) apresentaram em seu trabalho estudo sobre a influência da rugosidade. Já Soltani *et al.* (2011) estudaram contaminação das pás por acúmulo de sujeira. Danos causados por raios ou aves foram vistos no trabalho de Yokoyama (2013) que podem provocar diminuições na eficiência aerodinâmica e o desbalanceamento das pás.

Assim, faz-se necessário o desenvolvimento de técnicas de análise de vibração que sejam capazes de monitorar os níveis de vibração presentes em um aerogerador. Manutenções preditivas, aquelas baseadas na condição do equipamento, são pouco exploradas em turbinas eólicas, focando-se, principalmente, em análises de óleo e lubrificantes. Qualquer sinal de vibração presente faz com que a máquina pare de funcionar por completo, o que pode ocasionar perdas na produtividade. Investimentos em manutenção preditiva, por meio de análises de vibração, podem prolongar o

funcionamento dos equipamentos e reduzir os custos por paradas desnecessárias (Ponci *et al.*, 2021).

Melo Junior *et al.* (2019) captaram sinais de pás desbalanceadas propositalmente e estes foram processados e classificados por uma combinação de análise de flutuação destendenciada com a transformada de Karhunen-Loève, discriminador Gaussiano e Rede Neural Artificial, que são técnicas de reconhecimento de padrões com aprendizado supervisionado. Bons resultados foram alcançados empregando as técnicas de reconhecimento citadas acima, pois mais de 95% dos casos normais e desequilibrados foram classificados corretamente, e de uma maneira geral, também foi possível identificar diferentes níveis de desequilíbrio das pás

Com base nisto, visando se evitar pausas desnecessárias com manutenções preventivas e corretivas, a presente dissertação visa desenvolver um estudo para identificação de desbalanceamento nas pás de uma turbina eólica em escala através de análises da vibração. Para identificar os níveis de desbalanceamento, sinais de vibração foram coletados com diferentes condições de operação e pré-processados pela análise de flutuações destendenciadas (DFA) e, na sequência, classificados pela técnica de reconhecimento de padrões: rede neural de base radial.

2 JUSTIFICATIVA

Devido à necessidade de produção de energia elétrica sustentável, o uso de aerogeradores esta cada vez mais sendo empregado. Pelo uso constante dessas máquinas em ambientes abertos, muitos problemas podem ocorrer na estrutura dos aerogeradores, principalmente nas pás, por ficarem mais expostas, tais como acúmulo de gelo e erosão. Devido a esses problemas, os aerogeradores podem apresentar queda de rendimento e produção de energia, causando perda financeira. Para evitar o uso desnecessário e caro de manutenção corretiva, esta dissertação desenvolveu um método de previsão de falhas de pás eólicas através do uso de análise de vibração e classificação de dados através de redes neurais de base radial.

3 OBJETIVOS

Esta presente dissertação tem como objetivo a classificação em diferentes níveis de desbalanceamento de uma turbina eólica em escala utilizando DFA para análise de vibração e rede neural de base radial com classificador como meio de técnica de reconhecimento de padrão.

3.1 Objetivos específicos

Os objetivos específicos da presente dissertação são:

- Estudo bibliográfico relacionado ao tema;
- Classificar os padrões em estudo utilizando a técnica de rede neural de base radial e comparar com as técnicas usadas na literatura;
- Comparar os valores obtidos antes e depois do uso do método DFA;
- Avaliar o uso da técnica de classificação por meio de redes neurais.

4 FUNDAMENTAÇÃO TEÓRICA

Os aerogeradores tem sido cada vez mais utilizados pelos países ao redor do mundo, saindo de 62,9 TWh em 2003, para 1270 Twh em 2018, em termos de geração de energia elétrica (BP Wind Power Statistics, 2018). A necessidade surge pelo fator ambiental e sustentável na produção de energia elétrica.

Ao se estudar o uso e componentes de um aerogerador, observa-se que falhas podem ocorrer devido aos estresses causados através do tempo. As técnicas de detecção e predição de falhas podem ser utilizadas nessas máquinas para o aumento da vida útil e eficiência energética.

4.1 Classificação dos aerogeradores e seus componentes

Nos sistemas eólicos, a energia cinética contida nos ventos é convertida em energia mecânica rotacional nas pás da turbina, para a realização de trabalho mecânico ou conversão em energia elétrica.

As turbinas eólicas de eixo horizontal (TEEH) podem possuir números diferentes de pás. Segundo o Instituto Alemão de Energia Eólica (IAEE) (1998), quanto menor o número de pás mais rápido o rotor gira.

As turbinas de 3 pás apresentam uma melhor distribuição de peso, sendo, portanto mais estáveis. Isto, por sua vez, reduz as forças mecânicas nos demais componentes da turbina, principalmente, na torre. Adicionalmente, as turbinas de 3 pás devem apresentar menos ruído em função da menor velocidade rotacional se comparada às turbinas de 1 ou 2 pás, para um mesmo nível de energia elétrica gerada (CRESESB, 2008). Por fim, cabe mencionar que as turbinas eólicas podem ser classificadas de acordo com a posição do rotor em relação à torre (Lopes, 2009).

De acordo com Alvim Filho (2009), os principais componentes de uma turbina eólica de eixo horizontal são a nacelle, que é o componente, acima da torre, que abriga diversos outros componentes, tais quais o gerador, o sistema de transmissão de potência (eixos, sistemas hidráulicos e etc) e outros. A nacelle pode ter ou não uma caixa de engrenagens multiplicadora. Segundo Hau (2006), as pás são os principais componentes de uma turbina eólica e seu comprimento afeta diretamente a área varrida pelo rotor, o que determina a quantidade de potência que pode ser extraída do vento.

Normalmente as pás são fabricadas a partir de compostos sintéticos, tais quais plásticos reforçados com fibras de vidro. Também podem ser fabricadas com fibras de carbono, com custos mais elevados, porém com melhores características mecânicas;

O cubo por sua vez é o componente que recebe as pás, e junto com estas formam o rotor que transmite a energia captada pelas pás para o eixo, responsável por transferir a energia rotacional para uma caixa multiplicadora, no caso de geradores convencionais, ou então diretamente para o gerador, no caso de geradores multipolos.

A caixa de engrenagens (caixa multiplicadora) aumenta a velocidade do eixo entre o cubo do rotor e o gerador. Cabe mencionar que a velocidade de rotação de um rotor de grande porte é muito baixa (aproximadamente 10-30 rpm) se comparada à velocidade de rotação nominal de geradores elétricos convencionais (usualmente entre 1.200 rpm a 1.800 rpm). Este componente é dispensado no caso de geradores multipolos. Unindo a caixa de engrenagens ao gerador há o eixo de alta velocidade com freio mecânico.

O gerador elétrico usa a energia rotacional do eixo para gerar eletricidade via eletromagnetismo (Lei de Faraday), podendo ser convencional (com caixa multiplicadora) ou multipolos (sem caixa multiplicadora). Há também um controlador de orientação que move o rotor (*yaw*) para alinhá-lo com a direção do vento; sistema hidráulico; uma unidade de controle eletrônico que monitora o sistema, desliga a turbina em caso de mau funcionamento e controla o mecanismo de ajuste para alinhamento da turbina com o vento; unidade de resfriamento; unidade de medição de direção e velocidade do vento; e por fim a torre que sustenta o rotor e a nacelle e paralelamente, ergue todo o conjunto a uma altura onde as pás possam girar com segurança e distantes do solo (Burton, 2001).

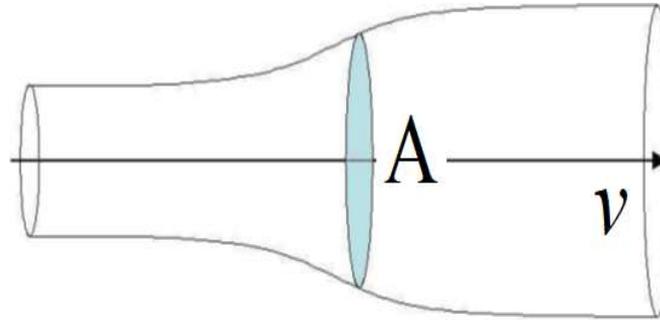
4.2 Energia cinética do vento

A produção de energia elétrica se dá pela transformação da energia cinética que provém da massa de ar em movimento, conhecida como “vento”. Essa massa de ar ao entrar em contato com as pás do rotor transfere parte de sua energia para a turbina eólica. Segundo a Equação 1 (Burton, 2001):

$$E = \frac{1}{2}mv^2 \quad (1)$$

Onde E (J) é a energia cinética, m é a massa (kg) de ar e v (m/s) é a velocidade do vento. O fluxo de massa de ar é representado na Figura 1.

Figura 1 - Fluxo de ar através de um disco de rotor.



Fonte: Adaptado de Betz, A. (1966).

A potência que está associada a essa massa de ar é a derivada da energia E ao longo do tempo. Pela equação da continuidade da mecânica dos fluidos, sabe-se que o fluxo de massa, dm/dt , é função densidade do ar, ρ , e a velocidade do ar, v (Burton, 2001):

$$\frac{dm}{dt} = \rho Av \quad (2)$$

Onde A (m^2) é a área varrida e pode ser representada conforme a Equação 3 (Burton, 2001):

$$A = \frac{\pi}{4} D^2 \quad (3)$$

Sendo que D é o diâmetro do rotor, dado em metros.

Substituindo a Equação 2 na Equação 1, obtém-se a potência contida no vento, conforme a Equação 4 (Burton, 2001):

$$P = \frac{1}{2} \frac{dm}{dt} v^2 = \frac{1}{2} \rho Av^3 \quad (4)$$

Pela Equação 4, nota-se que a potência é proporcional à densidade do ar, à área varrida pelo rotor e à velocidade (ao cubo) do vento. Logo, com o aumento da área dos rotores nos quais o vento passa em maior quantidade, tem-se maior potência. Além disso como pode-se observar, a velocidade por estar ao cubo, é um parâmetro importante no cálculo da energia.

4.3 Teoria da manutenção e adversidades em aerogeradores

Devido ao uso constante dessas máquinas e pelo fato dela ser utilizada em campo aberto, há uma preocupação em relação aos problemas que podem surgir, tanto externos (como desgaste das pás, acúmulo de gelo) ou internos (desgaste das engrenagens, trincas e rachaduras). Para evitar que essas falhas prejudiquem o funcionamento do aerogerador, técnicas de manutenção são utilizadas nessas máquinas.

É necessária a manutenção de aerogeradores para garantir que os componentes continuem a desempenhar as funções para os quais foram concebidos. O objetivo da manutenção é implantar recursos mínimos necessários para garantir que os componentes executem suas funções pretendidas corretamente, a fim de garantir a confiabilidade do sistema e recuperar avarias (Knezevic J, 1993).

A teoria clássica vê a manutenção como corretiva ou preventiva. A primeira (também conhecida como manutenção não programada ou baseada em falha) é realizada quando as turbinas quebram e quando são detectadas falhas ou ocorrem em qualquer um dos componentes. O condicionamento ou substituição imediata de peças pode ser necessária e resultará em tempo de inatividade não programado (Ben-Daya MS e Duffuaa AR, 2009).

Com boa aquisição de dados e processamento de sinal apropriado, as falhas podem ser detectadas enquanto os componentes estão operando e ações podem ser planejadas para evitar danos ou falhas de componentes.

Em um aerogerador, as pás possuem um papel importante, pois captam a energia dos ventos, além de ter um custo elevado. Sendo assim, as pás eólicas são cada vez mais objeto de estudo.

As pás sofrem ao longo de sua vida útil com muitas adversidades climáticas e por diversos fatores se desgastam. Reduções na potência gerada pela turbina podem ocorrer pelo desgaste e acúmulo de resíduos nessa região.

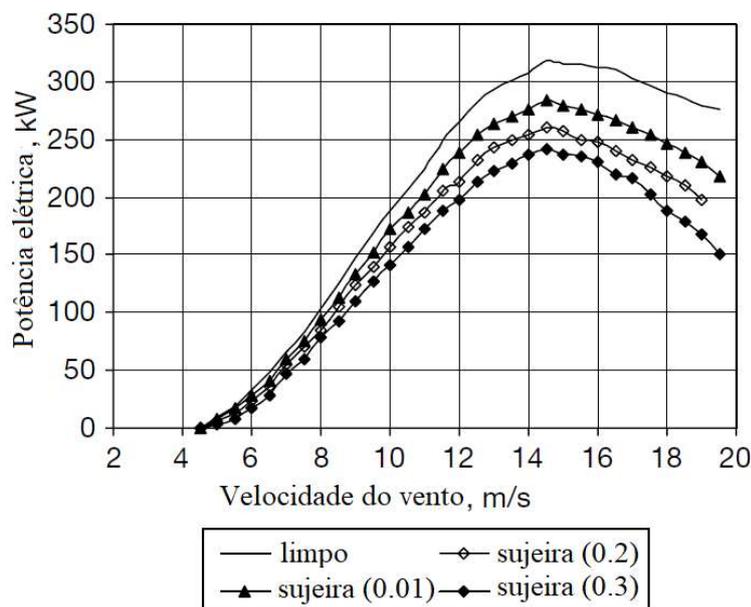
Cho *et al.* (2021) desenvolveram um método de detecção e diagnóstico de falhas para identificar automaticamente diferentes condições de falha de um sistema hidráulico de passo de pás em uma turbina eólica. Para detecção de falhas, um filtro de Kalman foi empregado para estimar o ângulo de inclinação da lâmina e a posição do carretel da válvula do sistema de inclinação da lâmina. O esquema de diagnóstico de falhas foi baseado em um método de rede neural artificial com aprendizado supervisionado que foi capaz de diagnosticar um tipo de falha predeterminado. O algoritmo da rede neural produziu um modelo preditivo com procedimentos de treinamento, validação e teste após a avaliação final de desempenho. Os procedimentos de validação e teste do modelo de rede neural artificial foram conduzidos com o modelo de treinamento para comprovar o desempenho do modelo. Os resultados do diagnóstico de falhas da avaliação final de desempenho mostraram que os métodos propostos funcionaram de forma eficaz e com bom desempenho.

Du *et al.* (2020) forneceram uma revisão abrangente das técnicas de detecção de danos de última geração para pás de turbinas eólicas (WTBs), incluindo a maioria dos métodos atualizados com base em medição de deformação, emissão acústica, ultrassom, vibração, termografia e visão de máquina. Em primeiro lugar, os danos típicos de WTBs foram introduzidos de forma abrangente. Em segundo lugar, os princípios de detecção, métodos de desenvolvimento, prós e contras das técnicas mencionadas para inspeção de lâmina e seus indicadores de falha foram revisados. Finalmente, as possíveis direções de pesquisa de técnicas de detecção de danos WTB foram abordadas por meio de uma análise comparativa e as conclusões foram tiradas.

Alterações no desempenho aerodinâmico de uma pá causadas por diferentes processos de erosão foram estudadas por Sareen *et al.* (2014). Erosões foram simuladas na pá, fazendo-se furos de 0,51 mm, 2,54 mm e 3,81 mm de diâmetro e profundidade. Além disso, foram simulados estágios de severidade para os furos. Os autores chegaram à conclusão que para pequenos furos a perda de energia chegou a 5%, e para maiores estágios de severidade, chegou a 25%.

O estudo de Khalfallah e Koliub (2007) mostrou a diminuição da energia elétrica gerada devido à presença de partículas de sujeira nas pás testadas, com diferentes espessuras e os efeitos, efeitos devido ao tempo expostas a essa sujeira e quantidade de área da pá coberta pelas partículas. Houve uma diminuição de cerca de 25% da energia elétrica gerada devido às partículas de diferentes espessuras, e em 9 meses chegou em 57%. A Figura 2 mostra essa variação.

Figura 2 - Variação da curva de potência devido a várias espessuras de partículas de sujeira.



Fonte: Adaptado de Khalfallah e Koliub (2007).

Com o avanço da tecnologia aplicada às pás, estas têm se tornado cada vez maiores, e por isso, os cuidados com segurança e integridade estrutural das máquinas tem aumentado também.

Um rotor que não está bem balanceado gera cargas excessivas que podem comprometer a estrutura do aerogerador seriamente.

Dentre os principais problemas que podem afetar o desempenho e estrutura dos aerogeradores, pode-se citar a incidência de raios, vazamentos de óleo da caixa de engrenagem, erosão do bordo de ataque, acúmulo de sujeira, insetos, gelo e outros. O surgimento de qualquer um desses problemas pode afetar a eficiência ou causar desbalanceamento do rotor, fazendo com que surjam vibrações, comprometendo, por exemplo a estrutura da torre.

Quando há acúmulo de gelo, como na Figura 3, essa contaminação também interfere na eficiência da turbina, pois alteram a forma aerodinâmica do perfil e a rugosidade da superfície.

Figura 3 - Rugosidades causadas por acúmulo de gelo.



Fonte: New Ice Age Begins (2018)

Os problemas relatados nessa seção podem causar a falha de componentes importantes dos aerogeradores, levando a um condicionamento ou substituição imediata de peças que resultará em tempo de inatividade não programado.

Por isso, a importância do estudo da análise de vibração, que pode ser feito através do modelo proposto nesta dissertação. O método foi proposto utilizando-se de acelerômetro para a captura de sinais de vibração do aerogerador em escala, causado por desbalanceamento induzido.

4.4 Análise de Vibração

A análise de vibração continua a ser “a tecnologia mais popular empregada em turbinas eólicas, especialmente para equipamentos rotativos” (Hameed *et al.*, 2009). Ainda segundo o autor, diferentes sensores são necessários para diferentes frequências: transdutores de posição são usados para a faixa de baixa frequência, sensores de velocidade na área de frequência média, acelerômetros na faixa de alta frequência e sensores de energia espectral emitida para frequências muito altas. Quanto às aplicações, é apropriado para monitorar a caixa de engrenagens, os rolamentos e outros elementos selecionados.

Tandon e Nakra (1992) apresentaram uma revisão detalhada dos diferentes métodos de medições, tais como medições de vibração nos domínios do tempo e

frequência, medições de som, o método do pulso de choque e a técnica de emissão acústica.

O princípio básico de utilização da análise de vibração como técnica preditiva consiste na identificação do nível de vibração que pode diferenciar o estado normal de funcionamento de uma situação com alguma irregularidade. Este método pode, ainda, relacionar o aspecto da vibração com a causa do problema (Melo, 2016).

Sendo o aerogerador um equipamento que gera energia elétrica através da transformação do movimento rotacional, ele está sujeito a vibrações causadas por desbalanceamento. As pás ao longo de sua vida útil podem se desgastar e sofrer alterações, gerando vibração que se propaga ao rotor e todo o restante da turbina. Isso pode gerar uma falha estrutural que compromete o funcionamento do equipamento.

Há dois métodos de análise do sinal de vibração: no domínio do tempo e no domínio da frequência. No domínio do tempo o sinal é representado pela forma de onda do sinal de vibrações. Ela mostra o que está ocorrendo a cada instante. O exame da forma de onda no domínio do tempo pode revelar detalhes importantes das vibrações que não são visíveis no domínio da frequência. Sua principal aplicação é identificar a ocorrência de eventos de curta duração, como impactos, e determinar a sua taxa de repetição. Existem várias maneiras de se definir o movimento vibratório no domínio do tempo por meio de expressões matemáticas, que podem ser simples, como de alta complexidade (Da Costa *et al.*, 2010).

Desde o início dos anos 1980, a tecnologia de energia eólica experimentou um imenso crescimento em relação ao tamanho da turbina e conseqüentemente, ao tamanho das pás. Devido à demanda por turbinas eólicas em grande escala e os custos de operação e manutenção cada vez mais altos, o interesse em sistemas de monitoramento tem aumentado também. De Azevedo *et al.* (2016) e García Marques *et al.* (2012) pesquisaram técnicas de monitoramento de turbinas eólicas, dentre elas, análise de vibração.

Um método para redução de vibrações causados pela turbulência de ventos variantes foi estudado por Staino *et al.* (2012). A proposta foi projetar uma pá com controladores a fim de amenizar as vibrações no sentido do bordo de ataque. Os resultados mostraram que o sistema de controle proposto foi capaz de reduzir os efeitos da vibração nas pás.

Zhao *et al.* (2020) estudaram a característica de vibração do aerogerador sob diferentes condições operacionais e foi observado que a condição de velocidade de

rotação nominal possui o maior nível de vibração. Os diagramas de Campbell da turbina eólica tanto na direção radial quanto na direção do eixo foram desenhados com base nos resultados de frequências naturais. Observou-se a partir dos diagramas de Campbell que quando a velocidade de rotação está próxima da velocidade de rotação conectada à rede, a frequência de passagem das pás é igual à frequência fundamental da turbina eólica que facilmente levará à ressonância.

Park *et al.* (2010) realizam um estudo vibracional na estrutura da turbina a fim de obter resultados sobre ressonâncias. Foi proposta algumas equações para o movimento das pás e as características vibratórias do movimento do rotor. Descobriu-se que em velocidades de rotação relativamente altas, a maioria dos programas comerciais não identificam com boa precisão as frequências de vibração das pás. Um método foi proposto para identificá-las, e segundo os resultados, se mostrou útil.

Para estudar o estado de saúde de componentes de turbinas eólicas, a análise de vibração foi utilizada por De Novaes Pires Leite *et al.* (2021). No trabalho os autores usam a decomposição do sinal do tempo, frequência e tempo-frequência. Dois conjuntos de dados reais de diferentes de turbinas eólicas operacionais foram caracterizados pelos métodos propostos. O resultado mostra que o método pode distinguir os níveis de falha, mas ainda apresenta algumas limitações pela complexidade dos sinais obtidos.

Um aerogerador possui uma vibração resultante complexa, por causa dos seus vários equipamentos que por si só, já produzem sua própria frequência de vibração. Isso torna os sinais aleatórios e não-estacionários, variando ao longo do tempo.

O comportamento vibracional das pás e de outros componentes de uma turbina eólica vem sendo estudado cada vez mais por cientistas do mundo todo a fim de se promover uma melhor eficiência energética e evitar danos no equipamento.

O método de DFA foi utilizado nesta presente dissertação a fim de se obter uma melhor análise dos sinais de vibração captados.

4.4.1 Método de identificação de afinidade em série temporal (DFA)

O DFA foi originalmente proposto para caracterizar os efeitos da memória de longo prazo na dinâmica variável no tempo dos sistemas fisiológicos (C.K. Peng *et al.*, 1994). No entanto, essa abordagem tem uma gama mais ampla de aplicações e pode ser usada para revelar correlações de diferentes tipos em séries temporais estacionárias e não estacionárias. Ele supera a análise de correlação convencional ao estudar intervalos de

longo prazo de atrasos, embora a caracterização de recursos de escala para correlações de curto alcance na dinâmica de sistemas com parâmetros estáveis possa ser melhor fornecida com a função de correlação tradicional.

Pensando em sanar a dificuldade na leitura de dados de vibração, o método DFA vem sendo usado em muitas áreas de pesquisa. Pavlov *et al.* (2020) estudaram características em reações a saltos repentinos da pressão arterial periférica em ratos. Eles usaram imagem em contraste para medir a velocidade relativa do fluxo sanguíneo cerebral e a DFA para o processamento dos dados experimentais para investigar diferenças nas respostas das veias e capilares. Os resultados mostraram distinções significativas nas respostas de pequenas redes de vasos sanguíneos.

Pavlov (2020) estudou os efeitos dos conjuntos de dados e o emprego da DFA para a solução de problemas. No primeiro trabalho os autores pesquisaram sobre o impacto de dados de vibração que possuíam ou não correlação com o objeto estudado. Foi demonstrado que os dados não correlacionados possuem uma alta sensibilidade à alternância entre diferentes estados do sistema, e presença de vários segmentos estranhos pode fornecer um deslocamento muito mais forte do expoente de dimensionamento, diferente da dinâmica correlacionada. Já no segundo trabalho, os autores estudaram o impacto de dados pertencentes ao conjunto de dados, mas não utilizados por serem fora do padrão. Chegou-se à conclusão que a “falta” desses dados não prejudica o resultado final da pesquisa, apesar do conjunto de dados ficar desfalcado.

Seguindo os estudos de vibração, DFA e classificação de sinais, Moura *et al.* (2016) propuseram identificar diferentes níveis de desequilíbrio em uma turbina eólica em escala por meio da análise de sinais de vibração. O experimento foi projetado de forma que os sinais adquiridos pudessem ser classificados de diferentes maneiras (em 3 e 7 classes). Uma combinação de DFA de sinais adquiridos e diferentes classificadores (Rede Neural Artificial, Classificador Gaussiano e Transformada de Karhunen-Loève) foram utilizados. Foi utilizada uma turbina eólica em escala a uma rotação de 900 rpm para os testes. Os resultados obtidos mostram que o classificador Rede Neural obteve o melhor resultado para 3 classes, e o pior para 7 classes.

O algoritmo do DFA inclui estimativa de um passeio aleatório ou perfil do sinal (Pavlov *et al.*, 2020). Através da DFA, é criado um parâmetro quantitativo que representa propriedades de longo alcance de um sinal aleatório. As tendências sistemáticas causadas por efeitos externos são eliminadas pelo método DFA, além de haver redução de ruídos indesejados capturados durante a fase experimental. Um sinal de

vibração é dado por $\{x_i\}$, $i = 1, 2, 3, \dots, N$, onde N é o comprimento da série, e inicialmente, determina-se a série acumulada, $\{y_i\}$, dada pela seguinte expressão referenciar as equações (Peng, 1995):

$$y(k) = \sum_{i=1}^k (x_i - x) \quad (5)$$

Onde x_i é a série temporal, x é o seu valor médio e $k = 1, \dots, N$. O perfil $y(k)$ é então separado em segmentos de tamanhos iguais n ($n \ll N$), e o desvio quadrático médio de $y(k)$ da tendência temporal é estimado (Peng, 1995):

$$F(n) = \sqrt{\frac{1}{N} \sum_{k=1}^N [y(k) - y_n(k)]^2} \quad (6)$$

A função $y_n(k)$ é calculada dentro de cada segmento de acordo com o ajuste de mínimos quadrados independentemente de outras partes dos dados. O caso mais simples considerado é usar uma função linear por partes como $y_n(k)$. Alternativamente, polinômios ou outros tipos de acessórios podem ser aplicados. Para muitas séries temporais naturais produzidas por sistemas complexos que operam sob um efeito combinado de fatores determinísticos e aleatórios, o desvio quadrático cresce com n , e um comportamento de lei de potência é tipicamente observado.

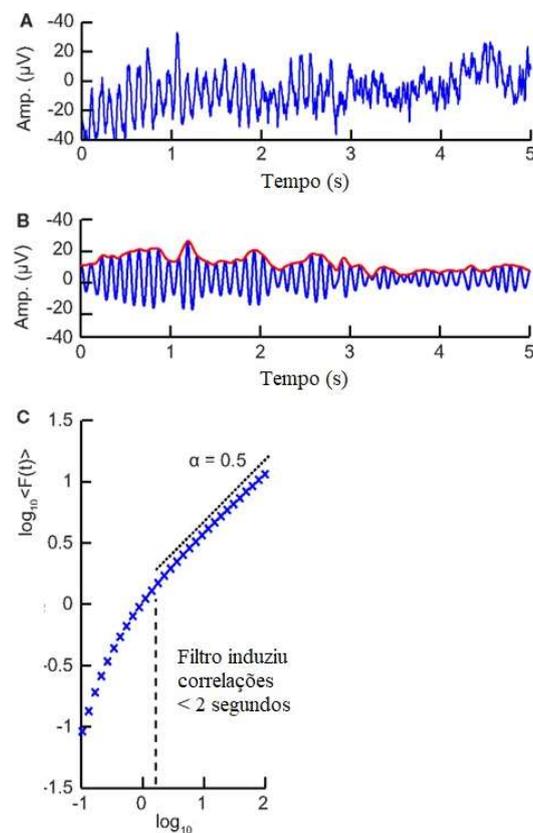
$$F(n) \sim n^\alpha \quad (7)$$

O expoente de escala α caracteriza correlações de vários tipos, incluindo os casos de correlações positivas ($1/2 < \alpha < 1$), anticorrelações ($\alpha < 1/2$), etc. Ao analisar a dinâmica estacionária, α tem uma relação com os expoentes descrevendo o decaimento da densidade espectral ou função de correlação (C.K. Peng *et al.*, 2009). É estimado como uma quantidade global em toda a faixa de n , ou localmente em diferentes faixas de escalas e é importante para processos não homogêneos cujas propriedades de escala são variadas.

Freitas *et al.* (2009) explicam que, em geral, usa-se o polinômio de grau linear para fazer o ajuste ($p = 1$), obtendo-se o DFA de primeira ordem, que retira tendências

lineares da função perfil $y(k)$. No entanto, polinômios de maior grau podem ser utilizados para retirar tendências de ordens maiores obtendo-se, para cada grau de polinômio p , um valor da função $Ys(i)$ e conseqüentemente um valor de DFA associado ao grau do polinômio. O Figura 4 mostra um gráfico produzido após o uso de DFA.

Figura 4 – Aplicação de DFA às oscilações neuronais. (a) Registro de sinal de EEG. (b) sinal filtrado (c) DFA aplicado ao envelope de amplitude do sinal de ruído branco filtrado.



Fonte: adaptado de Hardstone *et al.* (2012)

Um gráfico log-log da flutuação é calculado. Relações lineares no gráfico log-log indicam auto-similaridade e o coeficiente angular da reta obtida por regressão linear determina o expoente de auto-similaridade α , que quantifica a natureza das correlações da série temporal, segundo a Tabela 1.

Tabela 1 – Valores de α e suas relações.

Valores de α	Relações
$0 < \alpha < 0,5$	Anti-correlações
$\alpha \approx 0,5$	Ruído branco
$0,5 < \alpha < 1$	Correlações de longo alcance ou persistentes
$\alpha \geq 1$	Há correlação, mas é pouca

Fonte: Adaptado de Freitas (2009).

4.5 Aprendizado de máquina e análise de reconhecimento de padrões

Após a aplicação do método DFA, é necessário obter os coeficientes angulares da DFA por meio de técnicas de reconhecimento de padrões, que se encaixam nessa finalidade.

A pesquisa em aprendizado de máquina permite que as máquinas adquiram novos conhecimentos, novas habilidades e reorganizem o conhecimento existente (Nguyen e Armitage, 2008).

Como um processo de aprendizagem para encontrar e descrever padrões estruturais no conjunto de dados fornecido, o núcleo disso é usar algoritmos para analisar dados e, em seguida, tomar decisões sobre novos dados. Em geral, dados de treinamento massivos são inseridos para treinar o modelo, de modo que o modelo possa compreender as leis potenciais contidas nos dados e, em seguida, atingir o objetivo de classificar ou prever com precisão os dados recém-inseridos. O aprendizado de máquina é um assunto focado na resolução de dois problemas inter-relacionados, e por meio do aprendizado de dados e algoritmos para gerar modelos matemáticos, pode melhorar o desempenho em sistemas computacionais (Jordan e Mitchell, 2015).

Segundo Zhao *et al.* (2021), o aprendizado de máquina geralmente envolve processos de aprendizado, cujo objetivo é ganhar “experiência” com a amostra para apoiar a execução da tarefa. Com base no estilo de aprendizagem, o aprendizado de máquina pode ser dividido em quatro tipos de aprendizado: aprendizado supervisionado, aprendizado não supervisionado, aprendizado semi-supervisionado e aprendizado por reforço. O método mais utilizado é o aprendizado supervisionado, onde os dados amostrais do modelo de aprendizado de máquina treinado têm valores-alvo correspondentes (James, 2013).

O método proposto para a classificação dos dados se enquadra na divisão de métodos supervisionados, quando se possui uma amostra de dados conhecida onde se possa fazer treinamento, teste e depois mede-se a acurácia do método proposto.

Um estudo mais aprofundado sobre o uso de classificadores para análise de desbalanceamento em pás eólicas foi proposto por Melo Junior *et al.* (2019). Dessa vez foram utilizadas 3 velocidades de rotações diferentes (900, 1200 e 1500 rpm) para a análise de desbalanceamento. As técnicas de reconhecimento de padrão utilizados foram a ANN, CG e KLT, após os dados serem tratados pela DFA. Os resultados obtidos mostram que o uso de Rede Neural como classificador se mostra como boa opção, tanto para as velocidades de rotações individualmente, como em conjunto, simulando o funcionamento real de uma turbina eólica.

Zhou *et al.* (2021) compararam a eficiência de algoritmos de *Machine Learning* (ML), incluindo máquina de vetor de suporte (SVM), regressão logística (LR) e rede neural artificial (ANN) no processamento de sinais sEMG para reconhecimento de padrão de movimento do ombro. 80% dos conjuntos de dados sEMG recodificados foram usados para o treinamento para construir os modelos de ML e 20% foram usados para a validação do modelo e determinação da precisão dos algoritmos de ML no reconhecimento de padrões de movimento. A influência dos tamanhos da janela de tempo deslizante foi estudada para a otimização do algoritmo. A análise estatística foi realizada para determinar a diferença na precisão dos métodos de ML. Os resultados mostraram que houve uma diferença significativa entre os três métodos de aprendizado de máquina e diferentes tamanhos de janela de tempo deslizante. Não houve diferença significativa no tempo de sobreposição. A maior precisão foi de $97,41 \pm 1,8\%$ usando o método SVM. O melhor classificador para reconhecimento de padrões de movimento do ombro foi o SVM.

Liu *et al.* (2021) calcularam o carregamento de fadiga equivalente (EFL) contra os efeitos da esteira sob distribuições reais do vento. Os efeitos do espaçamento da turbina eólica no EFL indicaram que os efeitos da esteira entre as turbinas eólicas com espaçamento de aproximadamente 2 vezes o raio do rotor foram considerados. Posteriormente, o amortecedor de massa sintonizado (TMD) foi colocado na nacele para controlar passivamente as vibrações frente-ré. Foi desenvolvida uma ferramenta de otimização para TMDs baseada na rede neural de função de base radial e algoritmo genético, a qual foi comparada com as equações teóricas e análises paramétricas. A tecnologia de aceleração de GPU foi utilizada. Resultados numéricos mostraram que, sob

distribuições reais de vento, os TMDs obtêm redução de pelo menos 40,1% EFL, o que é 8,9% maior do que a otimizada teoricamente.

Uma nova metodologia de monitoramento de saúde estrutural (SHM), que usa Processos Gaussianos (GPs) foi proposto por Chandrasekhar *et al.* (2021). As propriedades de interesse foram as primeiras frequências da borda das pás. Os GPs foram usados para prever as frequências de borda de uma lâmina em relação a outra, depois que essas relações entre os pares de pás foram aprendidas quando as pás estão em um estado saudável. Ao usar essa abordagem, a metodologia de SHM proposta foi capaz de identificar quando as pás começam a se comportar de maneira diferente umas das outras ao longo do tempo. Para validar o conceito, o sistema SHM proposto foi aplicado a dados reais de pás de turbinas eólicas onshore, onde alguma forma de dano era conhecida por ter ocorrido. A análise do gráfico de controle mostrou que o sistema identificou com sucesso o início precoce dos danos seis meses antes de serem identificados e corrigidos.

Chen *et al.* (2021) usaram algoritmos para diagnóstico de falhas de duas turbinas. Dois modos de falha, acúmulo de gelo na lâmina e fratura da correia dentada da engrenagem, foram analisados usando dados SCADA. Um novo índice foi definido para avaliar o desempenho de diferentes algoritmos. Um novo algoritmo de transferência de aprendizagem estudado neste artigo, TrAdaBoost, provou ter um desempenho superior ao lidar com desequilíbrios de dados e distribuições diferentes. Uma nova abordagem para calibrar rótulos de dados usando algoritmos de transferência de aprendizagem também foi proposta, o que forneceu informações importantes sobre a aprendizagem não supervisionada para o diagnóstico de falhas em turbinas eólicas.

Os dados utilizados no trabalho de Xu *et al.* (2020) foram obtidos a partir de um sistema de controle supervisor e aquisição de dados. O algoritmo de otimização do enxame de partículas foi usado para otimizar a função kernel da máquina de vetores de suporte para estabelecer um modelo para prever se uma pá do aerogerador está congelada. Especificamente, em um primeiro momento, os dados foram pré-processados para eliminar informações aparentes sem gelo e os conjuntos de dados foram ainda mais equilibrados usando técnicas de subamostragem e sobreamostragem. Em segundo lugar, os valores apropriados foram selecionados de acordo com o mecanismo de congelamento. Os parâmetros ótimos da máquina de vetores de suporte foram obtidos usando o algoritmo de otimização de enxame de partículas. Finalmente, o valor característico e os parâmetros foram substituídos na máquina de vetores de suporte para avaliar o mecanismo de falha do congelamento da lâmina.

Lydia e Kumar (2020) apresentaram uma breve revisão das aplicações do aprendizado de máquina no monitoramento, modelagem e previsão de parques eólicos.

4.5.1 Redes Neurais Artificiais (RNA)

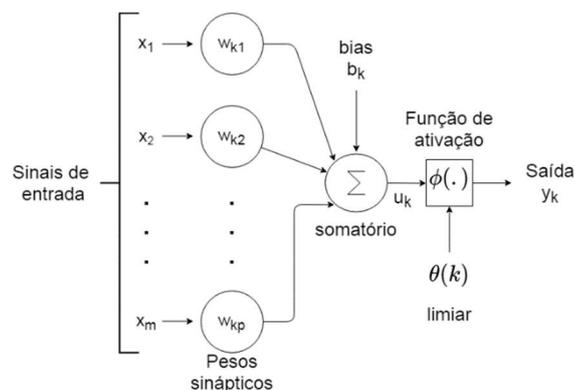
Segundo Rauber (2005) ele é composto por neurônios artificiais e tem como características o processamento de informações paralelas, aprendizagem, associação, classificação de padrões e memória.

Os neurônios artificiais são conceitualmente derivados de neurônios biológicos, possuem múltiplas entradas e produzem uma única saída que pode ser enviada para outros múltiplos neurônios.

O uso de vários neurônios em paralelo forma uma rede neural. Cada neurônio recebe sinais das variáveis de entrada (inputs) e passa adiante uma versão ponderada e tratada desses sinais. Em paralelo, essas estruturas formam uma camada oculta da rede neural. O output de cada neurônio funciona como input de uma outra camada oculta. Assim, segundo Squire (2012), pode-se empilhar camadas ocultas e produzir uma rede neural profunda.

As redes neurais artificiais possuem uma efetividade variável da transmissão de sinais que permite, assim como no cérebro humano, adaptar-se às diferentes situações. Isso é chamado de plasticidade sináptica, sendo utilizado na obtenção de melhores performances de aprendizados em diversos modelos. Também pode ser traduzida como a modificação (ou atualização) dos pesos sinápticos (Kriesel, 2007). A Figura 5 representa uma ilustração com os principais componentes de um neurônio matemático teórico.

Figura 5 –Principais componentes de um neurônio matemático teórico com função de ativação que possui limiar de ativação.

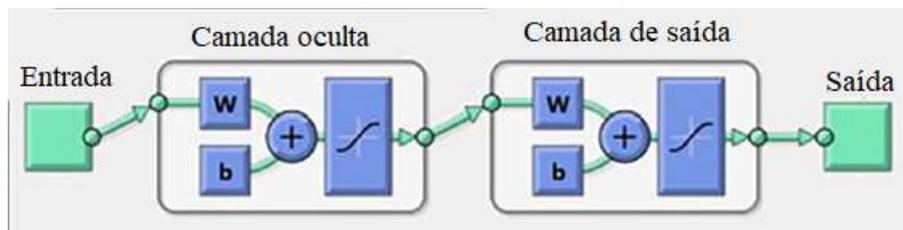


Fonte: Adaptado de Parmar (2020).

O neurônio artificial é um Perceptron que recebe diversos valores de entradas x_m . Essas entradas multiplicam-se pelo peso da sinapse w e, no final, somam-se formando um conjunto de entrada. Esse resultado passa por uma função de ativação e transmite a saída y_k . Quando o valor ξ exceder o limite da função de ativação, o neurônio será ativado e retornará um valor (Haykin, 2009).

Cada neurônio se comunica com um ou mais neurônios diferentes formando uma grande conexão entre essas estruturas. A Figura 6 mostra de forma gráfica uma RNA completamente conectada.

Figura 6 – Ilustração gráfica de uma RNA.



Fonte: Adaptado de Parmar (2020).

Portanto, as redes neurais artificiais se portam como um modelo não paramétrico, já que seus pesos sinápticos não apresentam um significado físico em relação ao problema. Isso influencia no objetivo do uso desse método, que é a estimação da função e valores de saída (Von Zuben; Attux, 2001).

Movsessian *et al.* (2021) apresentaram uma nova metodologia baseada em rede neural artificial (ANN) em uma estrutura de monitoramento de integridade estrutural baseada em vibração para detecção de danos robustos. A metodologia baseada em ANN estabeleceu as relações não lineares entre os recursos sensíveis a danos selecionados (DSF) influenciados por variabilidades ambientais e operacionais (EOVs) e seus índices de novidade correspondentes calculados pela distância de Mahalanobis (MD). O modelo de regressão ANN foi treinado e validado com base em um estado de referência (uma estrutura saudável). O modelo treinado foi usado para prever o MD correspondente de novas observações. O erro de previsão entre o MD calculado e o previsto foi usado como um novo índice de novidade para detecção de danos. Em primeiro lugar, um conjunto de recursos 2D artificial foi gerado para ilustrar como as limitações de usar apenas o índice de novidade baseado em MD podem ser superadas pela metodologia baseada em ANN proposta. Em segundo lugar, a metodologia foi implementada em dados obtidos de uma

turbina eólica em operação com diferentes cenários de danos induzidos artificialmente em uma de suas pás. Por fim, o desempenho da metodologia proposta foi avaliado pelas métricas de acurácia, pontuação F1 e coeficiente de correlação de Matthews. Os resultados demonstraram as vantagens da metodologia proposta ao melhorar a detecção de danos em todos os diferentes cenários, apesar da influência dos EOVs nos dados simulados e reais.

Chen *et al.* (2021) usaram um método baseado em rede neural de memória de curto prazo longa (LSTM) e auto-codificador (AE) para avaliar dados de monitoramento de condição sequencial da turbina eólica. Primeiro, um modelo de avaliação de desempenho foi construído usando unidades neurais LSTM e redes AE para calcular os índices de desempenho para avaliação do grau de anomalias no desempenho da turbina eólica. Em seguida, um método de estimativa de limite adaptativo com base no modelo de regressão de vetor de suporte foi desenvolvido para identificar as instâncias de dados anormais. A teoria da informação mútua foi posteriormente explorada para analisar as relações entre vários parâmetros de monitoramento e instâncias anormais de desempenho para identificar parâmetros de monitoramento de condição crítica. A eficácia do método proposto foi verificada por um estudo de caso usando dados de monitoramento de condições de turbinas eólicas (CM) do mundo real.

Zare e Ayati (2021) empregaram uma rede neural convolucional multicanal para desenvolver um algoritmo autônomo de diagnóstico de falhas baseado em banco de dados. Este algoritmo foi avaliado em um modelo de benchmark de turbina eólica de 5 MW. Várias falhas para várias velocidades do vento foram simuladas no modelo de referência e os dados de saída são registrados. Uma rede neural convolucional multicanal com várias camadas locais paralelas foi utilizada para considerar as mudanças em cada variável medida separadamente para identificar as falhas do subsistema. Sinais no domínio do tempo obtidos da turbina eólica foram retratados como imagens e alimentados de forma independente para a rede proposta. Os resultados mostraram que o esquema de diagnóstico de falhas multivariável diagnostica as falhas mais comuns em turbinas eólicas e atinge alta precisão.

4.5.2 Redes Neurais de Base Radial (RNBR)

As redes neurais de base radial apresentam uma única camada intermediária (oculta), seus neurônios de saída são lineares e as funções de ativação usadas são sempre de base radial (Von Zuben e Attux, 2001).

Funções de base radial são aquelas cuja resposta cresce ou decresce monotonicamente em relação a um ponto central. Valores como o centro, distância até ele, formato da curva e outros são fixos (Kriesel, 2007).

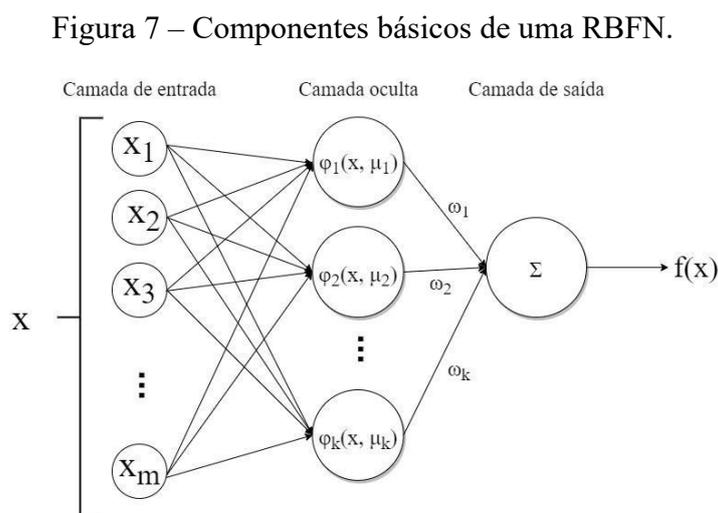
Um exemplo de função gaussiana, típica de rede neural, tem a seguinte estrutura (Von Zuben e Attux, 2001):

$$f(x) = \exp\left(-\frac{(x - c)^2}{r^2}\right) \quad (8)$$

Onde c representa o centro da função e r o raio que ela abrange. Graficamente, r define se a função é mais ou menos espalhada.

Para Haykin (2009), o entendimento acerca desse tipo de rede neural envolve uma aproximação híbrida entre dois estágios: o primeiro envolve a transformação de um espaço não linear em um espaço linearmente separável de alta dimensionalidade, o segundo é um estágio final baseado no método dos mínimos quadrados.

A Figura 7 a seguir apresenta a estrutura básica de uma RBFN.



Fonte: elaborada pelo autor.

Um vetor de entrada \mathbf{x} de dimensionalidade m é inserido na primeira camada. A partir dele, cada neurônio que compõe um total de k neurônios, onde $k < m$, recebe esse mesmo sinal de entrada e aplica em uma função de ativação φ . Cada função de ativação tem um centro $\boldsymbol{\mu}$ específico e, dessa forma, na camada oculta existem k neurônios com k funções de ativação relacionadas, cada uma com um centro $\boldsymbol{\mu}$ específico. A camada de saída $f(\mathbf{x})$ fornece a resposta da rede dado o estímulo inicial \mathbf{x} (Braga, 2019).

A Equação 9 mostra a função de ativação mais utilizada na RBFN. E segundo Haykin (2009) e Schwenker *et al.* (2001), problemas que envolvem aproximação de função o parâmetro σ , que representa o raio, pode ser mantido constante para as k funções de ativação distintas. Segundo Haykin (2009):

$$\varphi(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x} - \boldsymbol{\mu}\|^2}{\sigma^2}\right) \quad (9)$$

De acordo com Feng e Chou (2011), é comum que a saída de cada neurônio da camada oculta seja normalizada. Logo, a equação de saída de um neurônio i é:

$$\phi_i(\mathbf{x}) = \left(\frac{\varphi_i(\mathbf{x}, \boldsymbol{\mu}_i)}{\sum_{j=1}^k \varphi(\mathbf{x}, \boldsymbol{\mu}_j)}\right) \quad (10)$$

A função de saída da rede pode ser representada por (Feng e Chou, 2011):

$$f(\mathbf{x}) = \sum_{j=1}^k \omega_j \phi_j(\mathbf{x}, \boldsymbol{\mu}) \quad (11)$$

4.5.3 Otimização de hiperparâmetros (Grid Search)

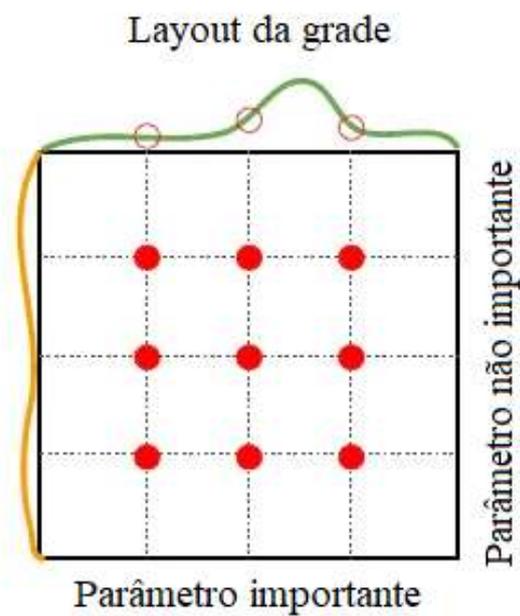
Segundo Alvarenga Júnior (2018) e Bergstra e Bengio (2012), os hiperparâmetros devem ser definidos e estão diretamente ligados ao desempenho do algoritmo. O hiperparâmetro é variado manualmente em busca de uma resposta satisfatória do algoritmo. O método usado no trabalho foi o Grid Search.

O Grid Search limita o intervalo de busca de um hiperparâmetro e depois escolhe quantos pontos dentro desse intervalo serão validados pela busca, causando a

criação de uma estrutura em grade formada pelo número de variações de cada hiperparâmetro. Esse método é usado quando se tem um número reduzido de hiperparâmetros, por causa do seu custo computacional.

A Figura 8 representa a grade formada pelo método de otimização e uma possível influência de nível de otimização para cada valor de cada hiperparâmetro. Nota-se que se um hiperparâmetro possuir picos de nível de otimização em determinado intervalo da busca, há chances, dado a devida divisão da grade de busca, de alcançar esse valor ótimo.

Figura 8 – Representação da grade criada pela variação de valores de hiperparâmetros no método Grid Search.



Fonte: Adaptado de Neptune (2020).

5 ESTUDO BIBLIOGRÁFICO

O presente trabalho busca fazer uma análise sobre as publicações na área de desbalanceamento de turbinas eólicas no contexto mundial, nacional e regional, mostrando os trabalhos com maiores citações e em que países e centros de pesquisa encontram-se mais publicações nesta área, considerando o contexto eólico, desbalanceamento, rede neural de base radial, análise de vibração e DFA.

5.1 Publicações envolvendo “desbalanceamento” e “turbinas eólicas”

Frequentemente, pesquisas estão sendo desenvolvidas e publicadas na área de energia eólica, uma das fontes renováveis que mais cresce no mundo, com o intuito de inovação neste campo de estudo, para buscar cada vez mais avanços e melhorias desta fonte.

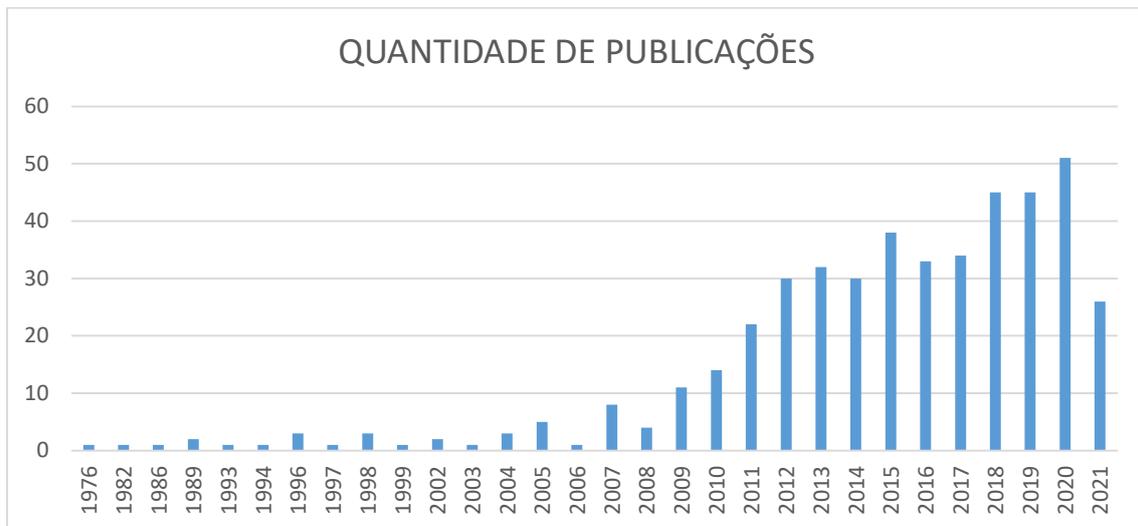
A base de dados da Scopus possui um banco de dados de resumos e trabalhos mostrando um panorama amplo da produção de pesquisas em todos os campos, e indicando as citações de cada um dos trabalhos na literatura.

O portal da Scopus pode ser acessado através do endereço: *scopus.com*, onde é possível ter acesso a qualquer trabalho da literatura.

Para esta pesquisa, inicialmente, realizou-se uma busca em inglês das palavras chaves “*Imbalance*” e “*wind turbine*” na base Scopus, considerando encontrar estes termos no título, *abstract* ou palavras chaves. Para esta busca, foram encontrados 450 documentos entre os anos de 1976 e 2021.

O Gráfico 1 mostra o número de publicações anuais no mundo correspondente aos resultados da busca considerado na base Scopus para as palavras chaves “*Imbalance*” e “*wind turbine*”.

Gráfico 1 – Quantidade de publicações por ano encontrados na base Scopus, considerando as palavras chaves “*Imbalance*” e “*wind turbine*”

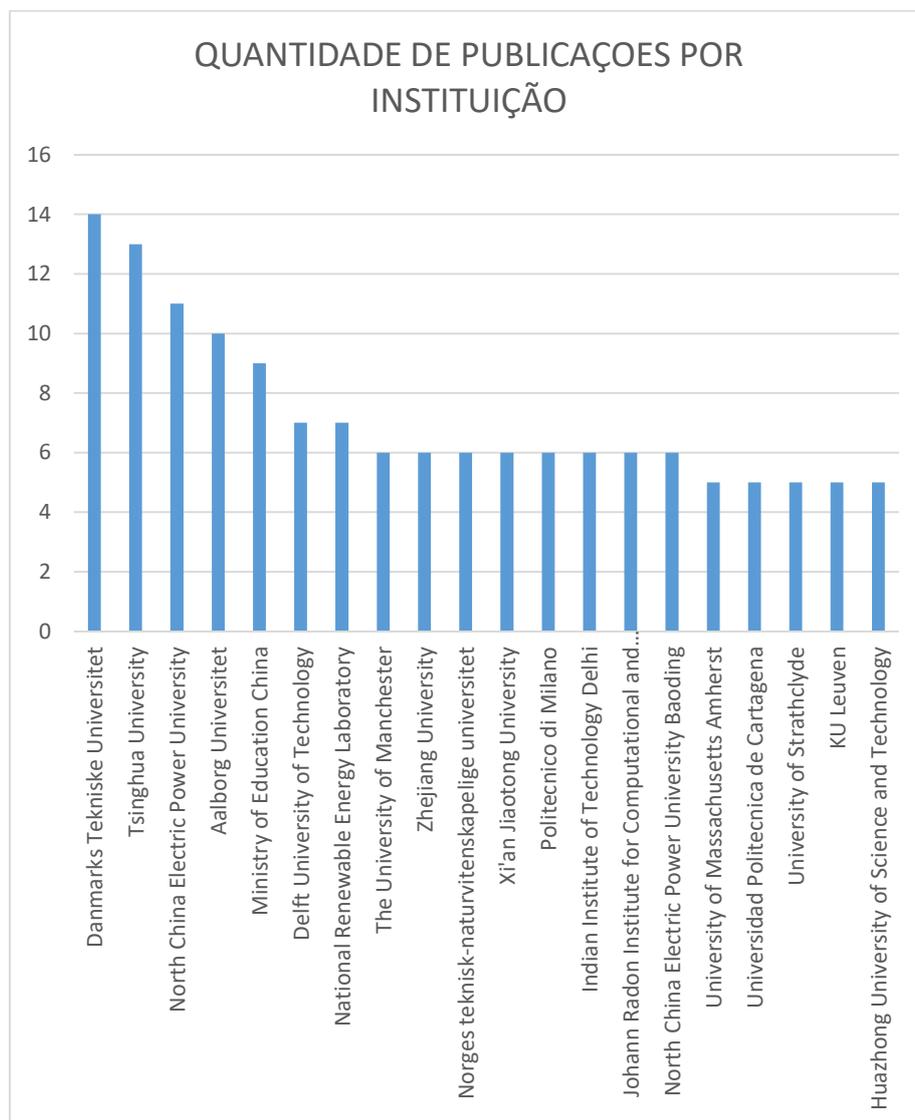


Fonte: elaborado pelo autor.

As pesquisas nesta área vêm tendo aumento ao longo dos anos, tendo maiores aumentos entre 2018 e 2020 quando atingiu um pico. Esse aumento de publicações nas últimas décadas deve-se ao fato de um maior interesse na eficiência e nas manutenções preditivas das turbinas eólicas, pois o desbalanceamento das pás pode causar perda de desempenho e danos estruturais.

O Gráfico 2 mostra as 20 instituições com mais publicações considerando esse resultado da busca, mostrando assim os centros de pesquisa vinculados ao tema em estudo.

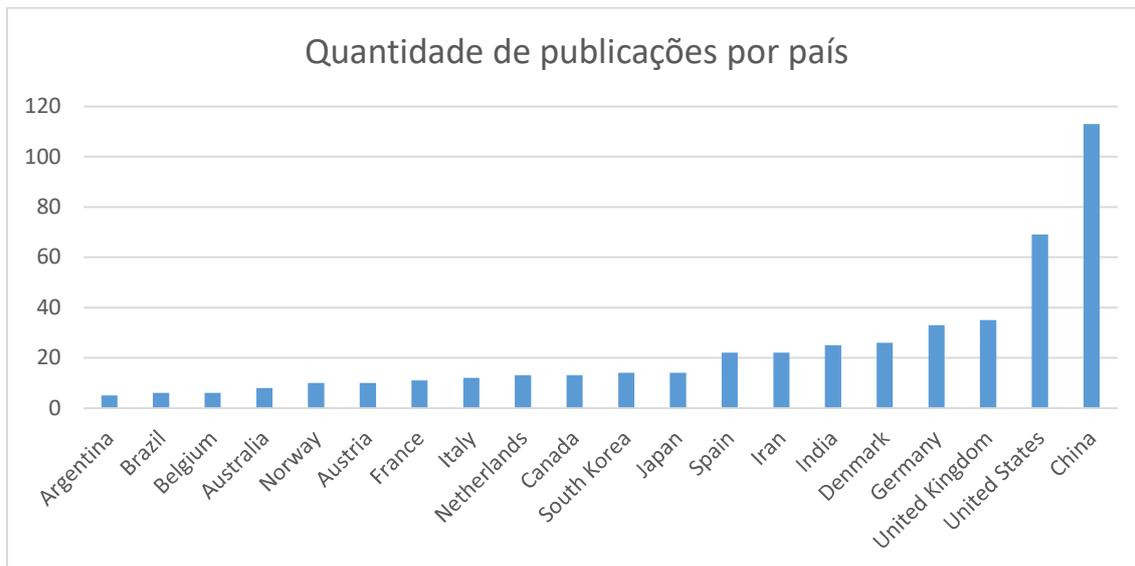
Gráfico 2 - Quantidade de publicações por instituições encontrados na base Scopus, considerando as palavras chaves “*Imbalance*” e “*wind turbine*”



Fonte: elaborado pelo autor.

O Gráfico 3 mostra 20 países que tiveram maior número de publicações relacionadas ao tema. A China lidera o ranking com 113 publicações, seguido pelos Estados Unidos, Reino Unido e Alemanha com 69, 35 e 33 publicações, respectivamente. O Brasil está em décimo nono lugar, tendo somente 6 publicações neste período. Percebe-se que o Brasil está muito atrás na pesquisa neste tema.

Gráfico 3 - Quantidade de publicações por país encontrados na base Scopus, considerando as palavras chaves “*Imbalance*” e “*wind turbine*”



Fonte: elaborado pelo autor.

No Brasil, há poucas publicações considerando esse resultado de busca. A Tabela 2 mostra os 6 artigos publicados nesta área de pesquisa com as respectivas citações para cada um deles.

Tabela 2 – Relação das publicações no Brasil

AUTORES	DOCUMENTO	ANO	CITAÇÕES
de Moura, E.P., de Abreu Melo Junior, F.E., Rocha Damasceno, F.F., Campos Figueiredo, L.C., de Andrade, C.F., de Almeida, M.S., Alexandre Costa Rocha, P.	Classification of imbalance levels in a scaled wind turbine through detrended fluctuation analysis of vibration signals	2016	13
Rahmann, C., Jara, J., Salles, M.B.C.	Effects of inertia emulation in modern wind parks on isolated power systems	2015	8
Alkmim, M.H., Fabro, A.T., de Morais, M.V.G.	Optimization of a tuned liquid column damper subject to an arbitrary stochastic wind	2018	4

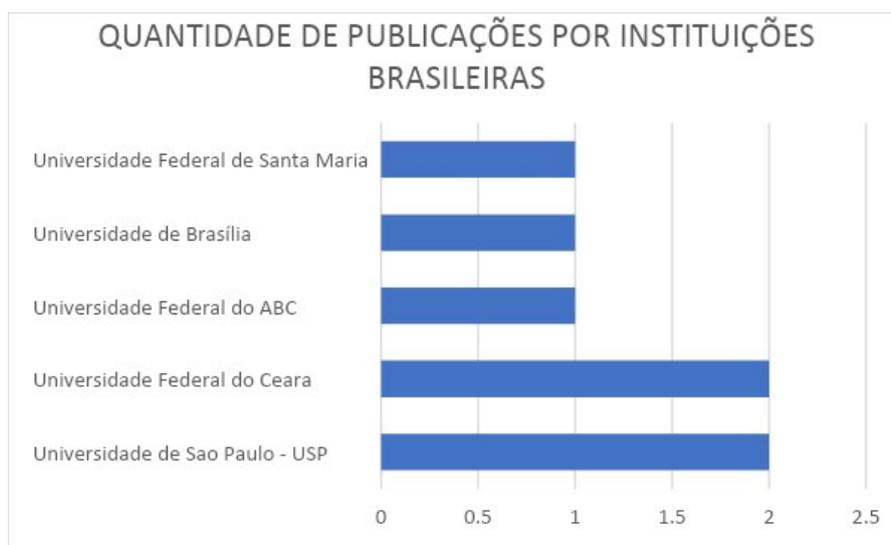
Melo Junior, F.E.D.A., de Moura, E.P., Costa Rocha, P.A., de Andrade, C.F.	Unbalance evaluation of a scaled wind turbine under different rotational regimes via detrended fluctuation analysis of vibration signals combined with pattern recognition techniques	2019	1
Hübner, G.R., Pinheiro, H., de Souza, C.E., Franchi, C.M., da Rosa, L.D., Dias, J.P.	Detection of mass imbalance in the rotor of wind turbines using Support Vector Machine	2021	0
Gomez, L.A.G., Lourenço, L.F.N., Grilo, A.P., Salles, M.B.C., Meegahapola, L., Sguarezi Filho, A.J.	Primary frequency response of microgrid using doubly fed induction generator with finite control set model predictive control plus droop control and storage system	2020	0

Fonte: elaborado pelo autor.

As instituições brasileiras que tiveram maior número de publicações relacionadas com o tema estão exibidas no Gráfico 4. A Universidade de São Paulo e a Universidade Federal do Ceará lideram o ranking com 2 publicações cada.

As citações que aparecem da Universidade Federal do Ceará são de Moura et. al. (2016) com 13 citações e Melo Junior et. al (2019) com 1 citação. Observa-se que a publicação da Universidade Federal do Ceará é a que tem maior número de citações nessa relação.

Gráfico 4 - Produção científica por instituições brasileiras relacionada ao tema pesquisado.



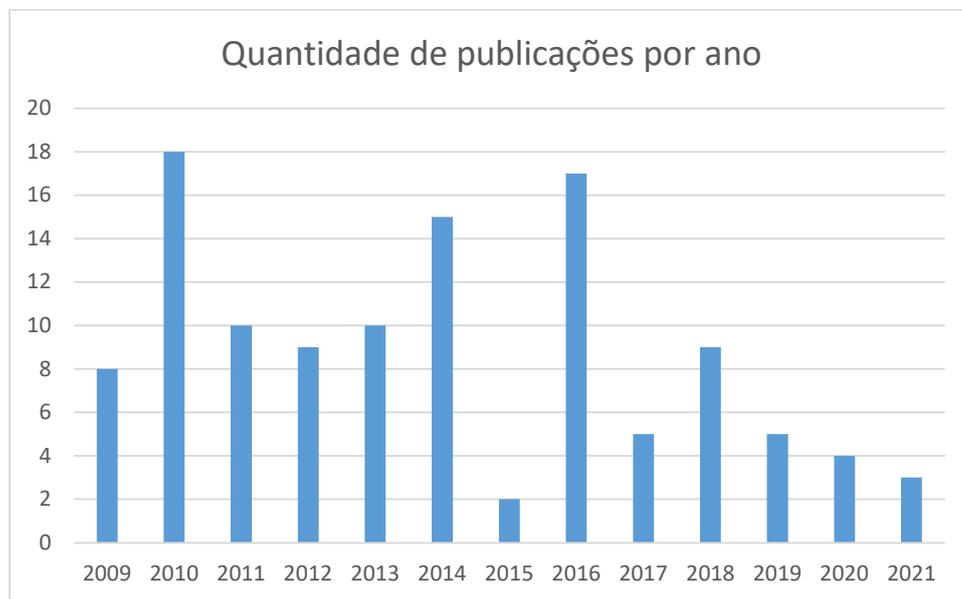
Fonte: elaborado pelo autor.

5.2 Publicações envolvendo “turbinas eólicas” e “rede neural de base radial”

Para esta etapa da pesquisa, realizou-se uma busca em inglês das palavras chaves “*wind turbine*”, “*neural network*” e “*radial basis*” na base Scopus, considerando encontrar estes termos no título, abstract ou palavras chaves. Para esta busca, foram encontrados 115 documentos entre os anos de 2009 e 2021.

O Gráfico 5 mostra o número de publicações anuais no mundo correspondente aos resultados da busca considerado na base Scopus para as palavras chaves “*wind turbine*”, “*neural network*” e “*radial basis*”.

Gráfico 5 - Quantidade de publicações por ano encontrados na base Scopus, considerando as palavras chaves "wind turbine", "neural network" e "radial basis".



Fonte: elaborado pelo autor.

Percebe-se que no ano de 2015 houve poucas pesquisas tendo o ano de 2010 e 2016 um aumento, onde atingiu um pico.

O Gráfico 6 mostra as 20 instituições com mais publicações considerando esse resultado da busca, mostrando assim os centros de pesquisa vinculados ao tema em estudo.

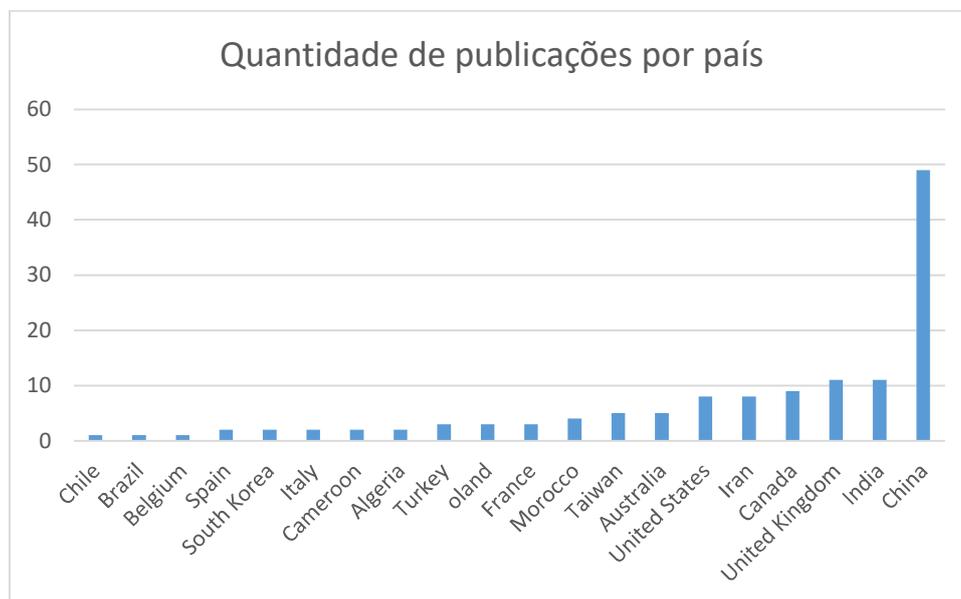
Gráfico 6 - Quantidade de publicações por instituição encontrados na base Scopus, considerando as palavras chaves “*wind turbine*”, “*neural network*” e “*radial basis*”.



Fonte: elaborado pelo autor.

O Gráfico 7 mostra os 20 países que tiveram maior número de publicações relacionadas ao tema. A China lidera o ranking com 49 publicações, seguido pela Índia, Reino Unido e Canadá com 11, 11 e 9 publicações, respectivamente. O Brasil está em décimo nono lugar, tendo somente 1 publicação. Mais uma vez, percebe-se que o Brasil está muito atrás na pesquisa neste tema.

Gráfico 7 - Quantidade de publicações por país encontrados na base Scopus, considerando as palavras chaves “*wind turbine*”, “*neural network*” e “*radial basis*”.



Fonte: elaborado pelo autor.

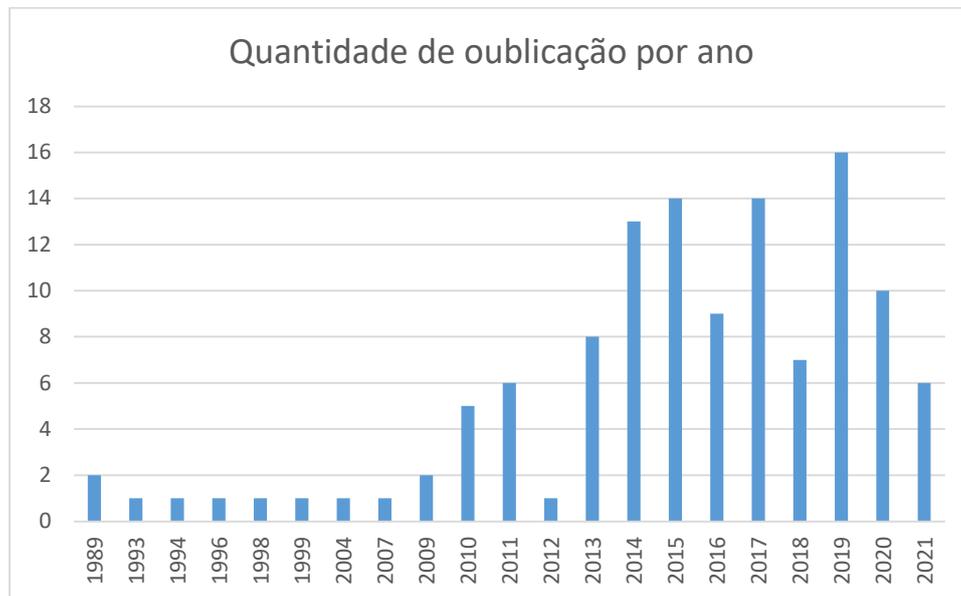
A única publicação do Brasil que aparece nesta busca é da Universidade Federal de Minas Gerais, dos autores Khosravi et. al. (2018), com 104 citações, onde os autores implementaram três modelos de algoritmos de aprendizado de máquina para prever a velocidade do vento, direção do vento e potência de saída de uma turbina eólica.

5.3 Publicações envolvendo “turbinas eólicas”, “desbalanceamento” e “pás eólicas”

Aqui, realizou-se uma busca em inglês das palavras chaves “*wind turbine*” “*blade*” e “*imbalance*” na base Scopus, considerando encontrar estes termos no título, abstract ou palavras chaves. Para esta busca, foram encontrados 120 documentos entre os anos de 1989 e 2021.

O Gráfico 8 mostra o número de publicações anuais no mundo correspondente aos resultados da busca considerado na base Scopus para as palavras chaves “*wind turbine*” “*blade*” e “*imbalance*”.

Gráfico 8 - Quantidade de publicações por ano encontrados na base Scopus, considerando as palavras chaves "wind turbine", "blade" e "imbalance".

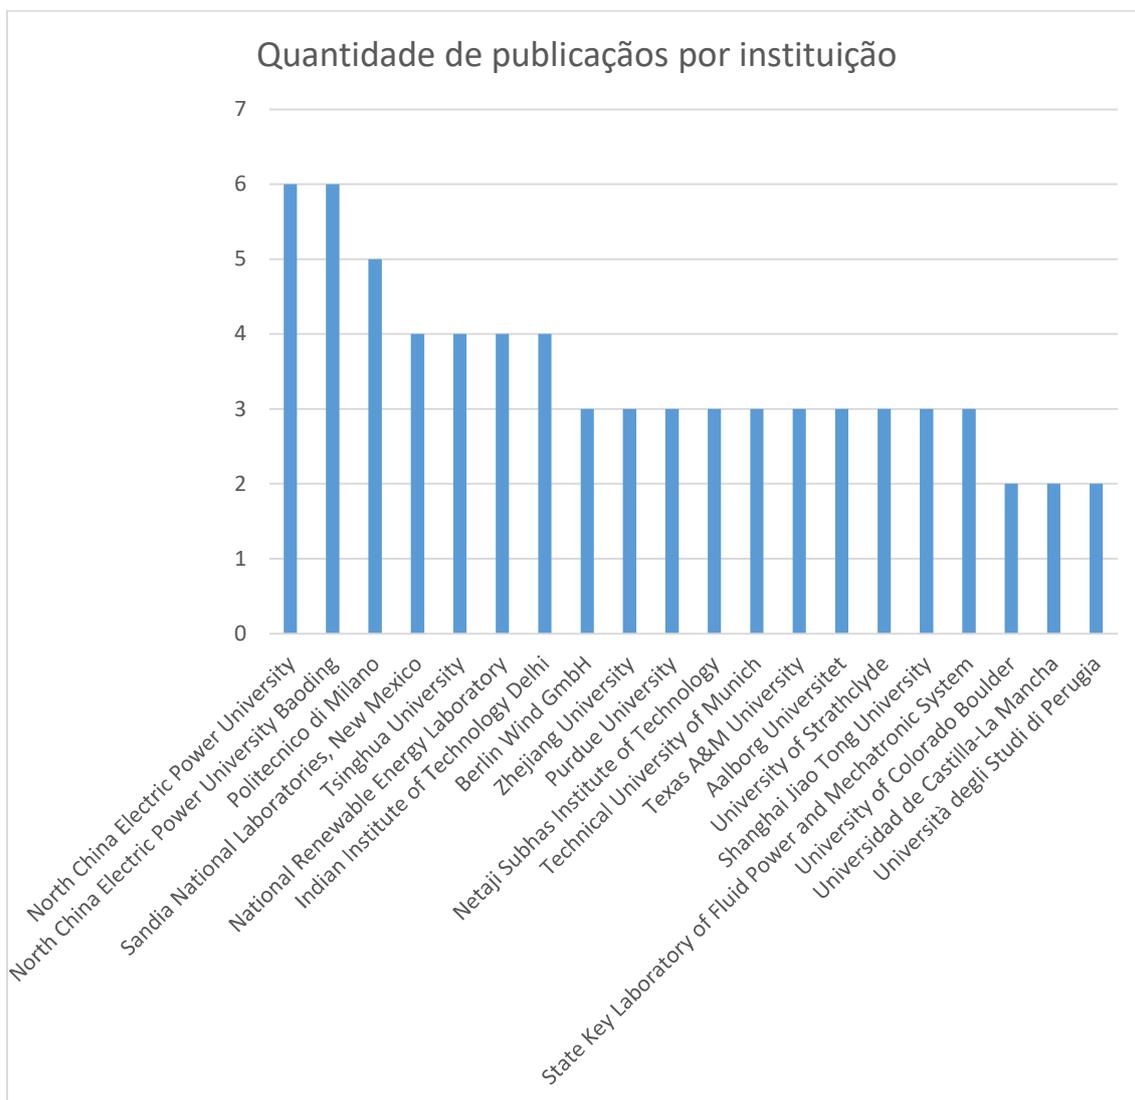


Fonte: elaborado pelo autor.

As pesquisas nesta área vêm tendo aumento ao longo dos anos, tendo maior aumento no ano de 2019 atingiu um pico.

O Gráfico 9 mostra as 20 instituições com mais publicações considerando esse resultado da busca, mostrando assim os centros de pesquisa vinculados ao tema em estudo.

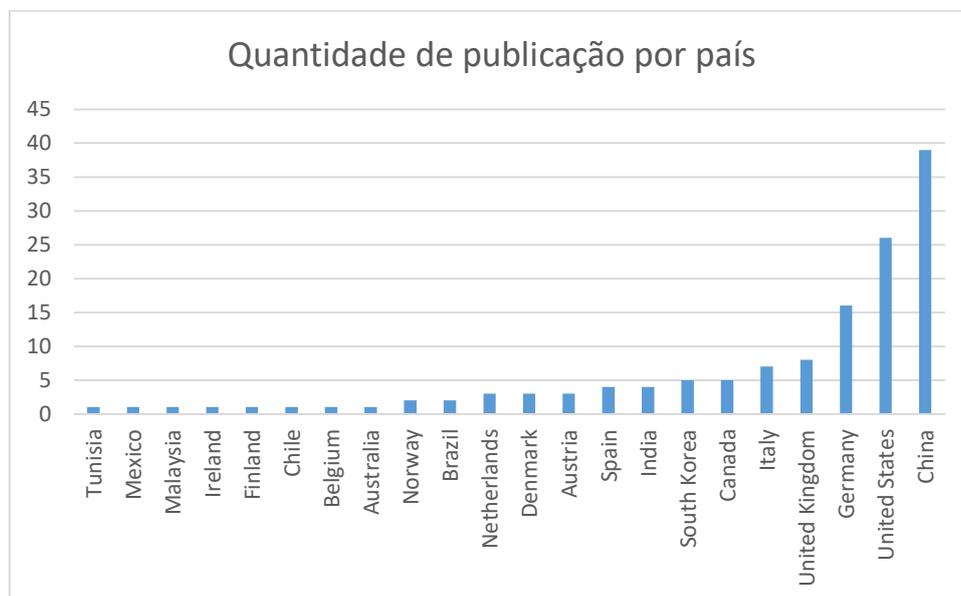
Gráfico 9 - Quantidade de publicações por instituição encontrados na base Scopus, considerando as palavras chaves "wind turbine", "blade" e "imbalance".



Fonte: elaborado pelo autor.

O Gráfico 10 mostra os 20 países que tiveram maior número de publicações relacionadas ao tema. A China lidera o ranking com 39 publicações, seguido pelos Estados Unidos, Alemanha e Reino Unido com 26, 16 e 8 publicações, respectivamente. O Brasil está em décimo terceiro lugar, tendo somente 2 publicações.

Gráfico 10 - Quantidade de publicações por país encontrados na base Scopus, considerando as palavras chaves "wind turbine", "blade" e "imbalance".



Fonte: elaborado pelo autor.

As publicações brasileiras são de Rahmann et. al (2015) da Universidade de São Paulo, tendo 8 citações e de Melo Junior et. al. (2019) da Universidade Federal do Ceará com 1 citação.

5.4 Pesquisas acadêmicas envolvendo “turbinas eólicas” e “vibração”

Nesta parte, realizou-se uma busca em inglês das palavras chaves "wind turbine" e "vibration" na base Scopus, considerando encontrar estes termos no título, abstract ou palavras chaves e encontrou-se 4.273 publicações. Para refinar esse resultado, considerou-se "wind turbine vibration" juntos, onde foram encontrados 114 documentos entre os anos de 1985 e 2021.

O Gráfico 11 mostra o número de publicações anuais no mundo correspondente aos resultados da busca considerado na base Scopus para as palavras chaves "wind turbine vibration".

Gráfico 11 - Quantidade de publicações por ano encontrados na base Scopus, considerando as palavras chaves “wind turbine” e “vibration”.

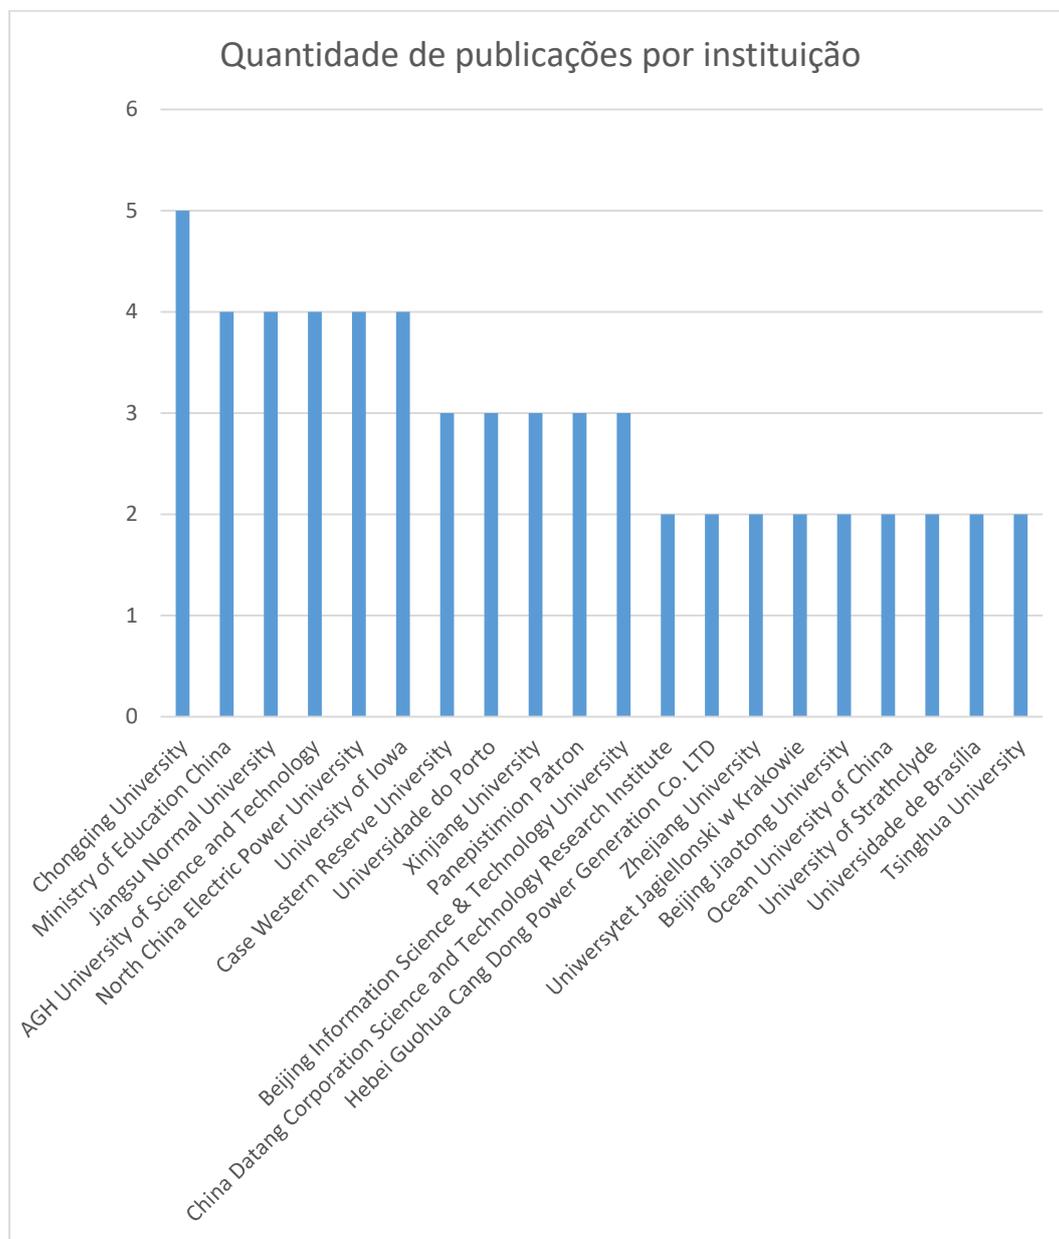


Fonte: elaborado pelo autor.

Percebe-se que o ano de 2013 foi o que mais teve publicações nessa linha de busca.

O Gráfico 12 mostra as 20 instituições com mais publicações considerando esse resultado da busca, mostrando assim os centros de pesquisa vinculados ao tema em estudo.

Gráfico 12 - Quantidade de publicações por instituição encontrados na base Scopus, considerando as palavras chaves “wind turbine” e “vibration”.

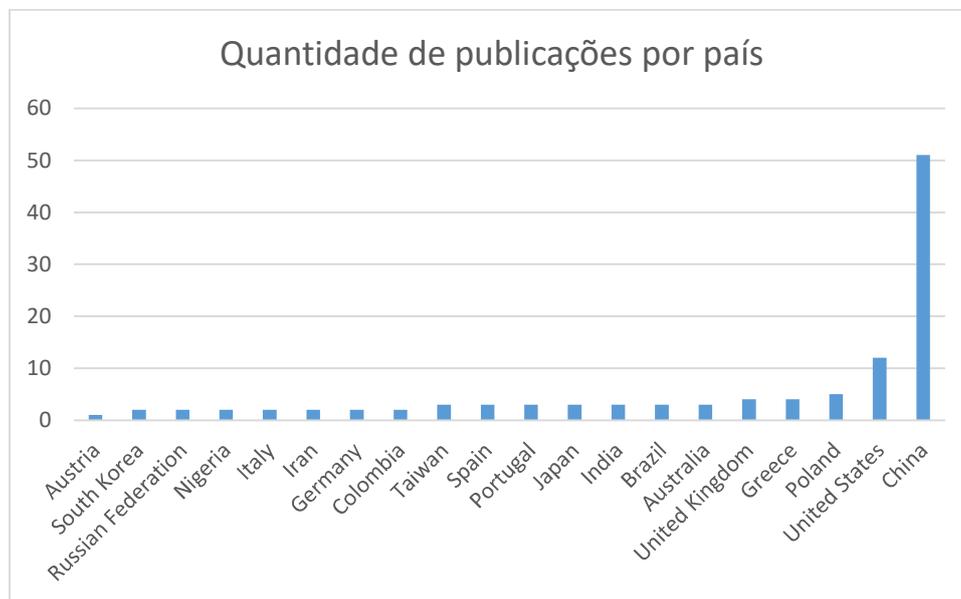


Fonte: elaborado pelo autor.

Pelo Gráfico 12, observa-se uma instituição brasileira entre as 20 primeiras instituições com publicação nessa área, sendo a Universidade de Brasília.

O Gráfico 13 mostra os 20 países que tiveram maior número de publicações relacionadas ao tema. A China lidera o ranking com 51 publicações, seguido pelos Estados Unidos, Polônia, Grécia e Reino Unido com 12, 5, 4 e 4 publicações, respectivamente. O Brasil está em sétimo lugar, tendo somente 3 publicações neste período.

Gráfico 13 - Quantidade de publicações por país encontrados na base Scopus, considerando as palavras chaves “wind turbine” e “vibration”.



Fonte: elaborado pelo autor.

Dentre os trabalhos desenvolvidos por instituições brasileiras está o trabalho de Guimarães et. al (2015) da Universidade de Brasília com 10 citações onde os autores falaram sobre os avanços na área de energia eólica que resulta em aerogeradores cada vez mais altos, intensificando as vibrações nas estruturas causadas pelo seu próprio funcionamento e, também, pela força do vento.

5.5 Pesquisas acadêmicas envolvendo “DFA” e “vibração”

Nesta parte, realizou-se uma busca em inglês das palavras chaves “*detrended fluctuation analysis*” e “*vibration*” na base Scopus, considerando encontrar estes termos no título, abstract ou palavras chaves e encontrou-se 93 publicações, entre os anos de 2003 e 2021.

O Gráfico 14 mostra o número de publicações envolvendo esses assuntos por países. Observa-se que o Brasil se encontra na quarta posição em número de artigos publicados, com 4 artigos. A China, com 56 publicações, lidera o ranking.

Gráfico 14 - Quantidade de publicações por país encontrados na base Scopus, considerando as palavras chaves “*detrended fluctuation analysis*” e “*vibration*”.

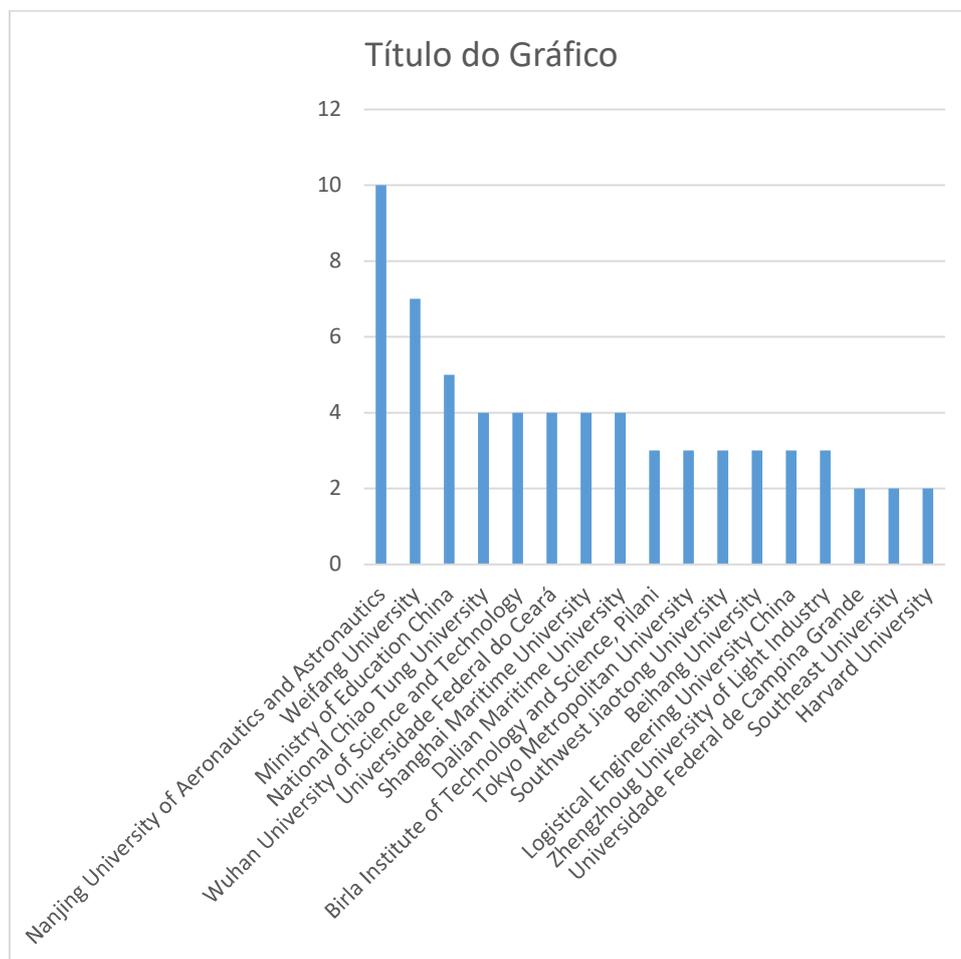


Fonte: elaborado pelo autor.

O Gráfico 15 mostra as 20 instituições com publicações considerando esse resultado da busca, mostrando assim os centros de pesquisa vinculados ao tema em estudo.

Observa-se pelo Gráfico 15 que duas instituições brasileiras estão entre as 20 primeiras instituições com publicação nessa área, sendo a Universidade Federal do Ceará, em quinto lugar, com 4 publicações, e a Universidade Federal de Campina Grande, com 2 publicações, em décimo sexto lugar.

Gráfico 15 - Quantidade de publicações por instituição encontrados na base Scopus, considerando as palavras chaves “*DFA*” e “*vibration*”.



Fonte: elaborado pelo autor.

Pode-se observar, de acordo com os gráficos presentes nesta seção, que as pesquisas relacionadas aos temas abordados nessa dissertação vêm aumentando ao longo do tempo. Isso se dá pelo aumento da importância do cenário energético de energias renováveis, e consequentemente de energia eólica. Além disso, temas como vibração e redes neurais são cada vez mais presentes no cenário de turbinas eólicas, pois através delas é possível analisar a causa de problemas e evitá-los.

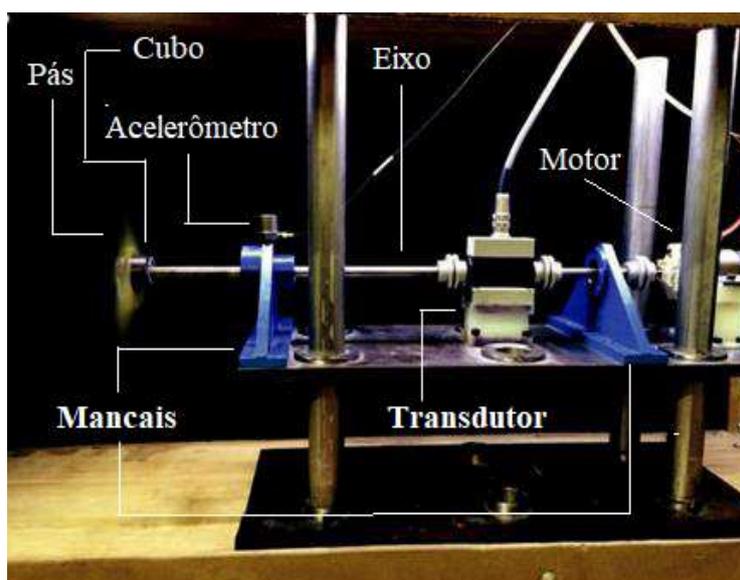
6 METODOLOGIA

O aparato experimental utilizado para fazer a captura de sinais encontra-se no Laboratório de Energia Eólica e Mecânica dos Fluidos Computacionais (LAERO) do Departamento de Engenharia Mecânica da Universidade Federal do Ceará e foi construído por Almeida (2013).

A bancada dispõe de um eixo, um transdutor de torque, um motor elétrico e dois mancais, que sustentam o eixo. A placa inferior da bancada é fixa, e a outra placa (superior), é móvel, para que possa ser ajustada a altura do rotor.

Na ponta do eixo fica o rotor, composto pelo cubo e as pás, e no primeiro mancal fica o acelerômetro, utilizado para capturar os sinais de vibração, como visto na Figura 9.

Figura 9 – Bancada de testes



Fonte: Melo Junior (2016).

Os sinais de vibração foram capturados por De Moura *et al.* (2016), considerando as seguintes situações para simular condições similares de operação. Uma série de desbalanceamentos na turbina por adição de massa foi induzida:

- Adição de massas de 0,5, 1,0 e 1,5 g na ponta de uma pá para simular o desbalanceamento causado por erosão, acúmulo de sujeira ou objetos presos em uma pá, por exemplo.

Figura 10 – Representação do posicionamento dos pesos adicionados em uma pá



Fonte: elaborado pelo autor.

- Adição de massas de 0,5, 1,0 e 1,5 g em duas pás para simular o desbalanceamento por falta de massa na outra pá causado, por exemplo, por quebra ou perda de massa.

Figura 11 – Representação do posicionamento dos pesos adicionados em duas pás



Fonte: elaborado pelo autor.

- Sem adição de massa nas pás, o que simula o aerogerador perfeitamente balanceado.

Figura 12 – Representação de pá sem adição de massa



Fonte: elaborado pelo autor.

6.1 Processamento dos sinais de vibração

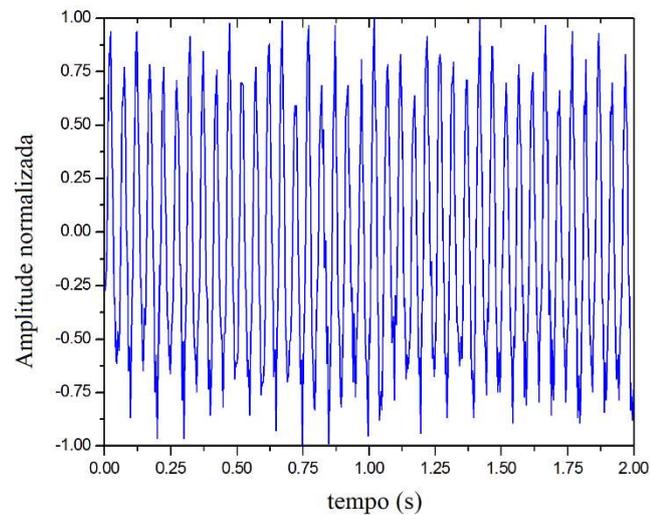
Inicialmente os sinais foram capturados somente com o eixo em funcionamento, sem as pás, para fim de comparação com um sistema balanceado somente com as pás, sem peso algum. Cinquenta sinais de vibração foram coletados para cada rotação. Para cada um dos sete níveis de desequilíbrio, cinquenta sinais de vibração foram adquiridos, rendendo 350 sinais.

Além disso, para todas as condições acima citadas, a turbina funcionou em três frequências de rotação (900 rpm, 1200 rpm e 1500 rpm), resultando em um conjunto de dados composto por 1050 sinais.

Cada sinal possui 500 pontos de dados adquiridos com uma taxa de amostragem de 250 Hz (250 amostras/s), de acordo com o Teorema de amostragem de Nyquist.

Um exemplo de sinal de vibração normalizado a 1200 rpm está representado na Figura 13.

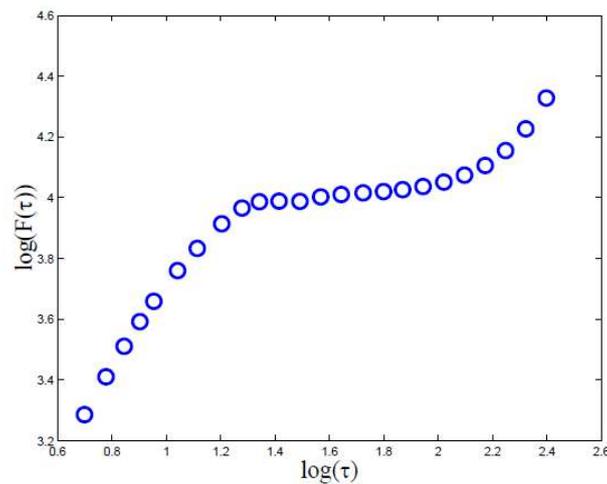
Figura 13 – Representação de sinal de vibração normalizado em uma turbina eólica em escala com uma pá com adição de peso em rotação de 1200 rpm.



Fonte: Adaptado de Moura *et al.* (2016)

Os sinais passaram pela análise de flutuações destendenciadas (DFA), gerando vetores com vários componentes, ou características. A repetição desse processo para diferentes tamanhos de intervalo criou uma curva da flutuação média em função do intervalo de tamanho. A Figura 14 mostra $F(\tau)$ contra (τ) , segundo a Equação 7.

Figura 14 – Representação de curva DFA gerada pelo sinal obtido na Figura 13.



Fonte: Adaptado de Moura *et al.* (2016).

Vale ressaltar que alguns pontos ao final da série temporal não são analisados se o comprimento da série não for um múltiplo de τ , pelo fato da série temporal conter uma certa tendência e as janelas terem tamanhos diferentes (Peng, 1995).

Os vetores gerados pela DFA passaram, então, pelos processos de classificação de Redes Neurais Artificiais (RNA).

Os dados iniciais dos resultados através da RNBR foram:

1) Estrutura da rede: camada de entrada com k neurônios + Camada de saída com m neurônios (m = número de classes);

2) Função: função gaussiana. Parâmetro principal: Sigma – Obtido através do *GridSearch*;

3) Outros parâmetros: número de neurônios da camada de entrada: K – Obtido através do *GridSearch*; Bias: b – Utilizado como valor 1 na camada de entrada;

4) Normalização: realizada apenas nos parâmetros de entrada. $[0,1]$;

5) Observações: foi realizada uma alteração na estrutura da rede para adaptá-la a classificação. Foram acrescentados neurônios de saída conforme o número de classes. Dessa forma, para um problema de 3 classes, existiam 3 neurônios de saída cuja resposta, por exemplo, esperava-se ser $[1,0,0]$ caso o dado fosse da primeira classe, $[0,1,0]$ caso fosse da segunda da classe, e $[0,0,1]$ caso fosse da terceira classe. A busca dos k pesos sinápticos apresentados no Tópico 3.5.1 desta dissertação foi então transformada em buscas de $k \times m$ pesos sinápticos, segundo a estrutura base de uma rede neural artificial (Haykin, 2009). Tomando o problema de forma separada, a solução algébrica para o problema foi realizada m vezes, uma para cada classe, onde, como no exemplo anterior, o valor buscado na primeira vez seria 1, na segunda seria 0 e na terceira 0. Cada vez tendo seus próprios k pesos sinápticos a serem atualizados.

O método *GridSearch* foi aplicado para cada teste mencionado acima com o objetivo de buscar os melhores parâmetros (Sigma e K) da rede neural para cada problema.

Para cada configuração de experimento testada, o algoritmo de classificação foi aplicado 100 vezes, toda vez separando-se aleatoriamente 80% dos dados para etapa de treinamento e 20% dos dados para etapa de teste. Vale ressaltar que esses valores se referem apenas a verificação da etapa de teste, ou seja, o treinamento não faz parte das estatísticas de acerto/erro. Para a melhor configuração de parâmetros encontrada no *GridSearch*, foi montada uma matriz de confusão com as médias de acerto e erro das 100 rodadas.

A matriz de confusão permite uma visualização do desempenho do algoritmo do classificador. As linhas mostram as classes verdadeiras, ou reais, enquanto as colunas representam as classes previstas, como visto na Figura 15. Espera-se que o cruzamento da linha e coluna de uma mesma classe obtenha o resultado de 100%, ou seja, o resultado máximo. Isso significa que para cada valor verdadeiro da classe testado, o algoritmo de classificação prevê essa mesma classe.

No cruzamento entre classes diferentes espera-se que os valores sejam mais próximos ou iguais a 0%, o que significaria que o algoritmo não classifica erroneamente o classificador.

Os parâmetros que obtiveram as melhores taxas médias de acerto foram colocados nas tabelas 4 e 5, para as 3 e 7 classes e nas três rotações de estudo: 900, 1200 e 1500 rpm.

6.2 Classificação dos sinais

Nesta presente dissertação, foram elaborados dois diferentes conjuntos de dados: de 3 e 7 classes, de acordo com o nível de desbalanceamento das pás. As Tabelas 3 e 4 representam a nomenclatura usada em cada classe.

Tabela 3 – Nomenclatura para as 3 classes utilizadas para a classificação.

Classe	Significado da Classe
CD1 -	Desbalanceamento por excesso de massa em uma pá
CD2 -	Desbalanceamento por falta de massa em uma pá
CN0_SP0 -	Sistema balanceado

Fonte: Elaborada pelo autor

No primeiro caso, de acordo com a Tabela 3, as classes foram divididas em 3 níveis de desbalanceamento, não levando em consideração a intensidade de desbalanceamento.

Já na Tabela 4, foi levado em consideração 7 níveis diferentes de desbalanceamento.

Tabela 4 – Nomenclatura para as 7 classes utilizadas para a classificação.

Classe	Significado da Classe
CD1 - 0,5 g	Classe com acréscimo de 0,5g em 1 pá
CD1 - 1,0 g	Classe com acréscimo de 1,0g em 1 pá
CD1 - 1,5 g	Classe com acréscimo de 1,5g em 1 pá
CD2 - 0,5 g	Classe com acréscimo de 0,5g em 2 pás
CD2 - 1,0 g	Classe com acréscimo de 1,0g em 2 pás
CD2 - 1,5 g	Classe com acréscimo de 1,5g em 2 pás
CN0_SP0	Classe sem acréscimo nas pás ou eixo sem pás

Fonte: Elaborada pelo autor

Todas as classes foram testadas em 3 níveis de rotação de 900 rpm, 1200 rpm e 1500 rpm. Em seguida, foram geradas matrizes de confusão das classes em cada nível de rotação. Os resultados são obtidos em porcentagem de acerto.

As matrizes de confusão média confrontam as classes reais (linhas) versus a saída do classificador (coluna). Quanto mais próximo de 100%, melhor é o resultado do classificador, pois significa que o valor de saída do classificador se aproxima da classe real, logo a função de classificação obtida é válida para esse tipo de caso. Além disso, como o valor máximo possível é 100%, a soma dos valores das linhas tem que ter como resultado 100%, como mostrado na Figura 15.

Figura 15 - representação de matriz de confusão

1	92.1%	7.9%				
2		100.0%				
3		3.0%	94.5%	1.8%		0.6%
4	0.6%	3.0%		95.8%	0.6%	
5		1.8%			98.2%	
6	0.6%	5.5%				93.9%
	1	2	3	4	5	6

Classe Prevista

Fonte: Adaptado de Narayan (2021).

6.3 Sinais originais x sinais após DFA

Além de serem produzidas matrizes de confusão média para os sinais após a DFA, também foi produzida essa matriz sem a análise de DFA, ou seja, com os sinais originais, para fins de comparação sobre o método.

As Tabelas 6 e 7 mostram os melhores valores de *GridSearch* para 3 e 7 classes, como exemplo, levando em consideração os sinais originais (50 sinais para cada nível de desequilíbrio) e os sinais após DFA. A taxa de acerto média de maior valor serviu de comparação para se saber quais os melhores parâmetros para cada tipo de nível de desequilíbrio (1 pá desbalanceada, duas pás desbalanceadas ou sistema balanceado) em cada rotação (900, 1200 e 1500 rpm).

O número de neurônios da rede, K , pode ir de 1 até o número máximo de dados de entrada. No caso, esse número máximo de entrada foi o número de dados de treinamento, 80% do total de dados. Dessa forma, trabalhou-se dentro desse intervalo.

O sigma sendo o espalhamento da função de cada neurônio/centro não tem um limite claro. Partindo dessa proposta e de simples testes manuais, fica mais evidente que um valor de 0.001 ou um valor de 200 não são valores úteis e passíveis de serem testados. Então, sim, definiu-se de forma manual o intervalo de testes, baseado tanto em testes iniciais simples manuais, quanto valores já obtidos anteriormente em outros projetos, quanto os valores que outros métodos analíticos sugerem. Contudo, mesmo esses métodos analíticos que já nos dão uma fórmula pronta, não chegam nos melhores resultados. Portanto foi aplicado o *GridSearch*, para poder fazer uma varredura.

Os valores obtidos das melhores taxas médias de acerto, como sua taxa mínima e máxima, são mostrados nas Tabelas 5 e 6.

A descrição “Sigma: 0.3:0.5:2.8 / K:50:50:300” acima de cada tabela, significa o intervalo de busca proposto para o *GridSearch*, ou seja, nesse caso específico, buscou-se Sigma entre os valores 0.3, 0.8, 1.3, 1.8, 2.3 e 2.8 (de 0.3 a 2.8 com passe de 0.5) e K entre os valores 50, 100, 150, 200, 250 e 300 (de 50 a 300 com passe de 50).

Tabela 5 – Taxa média de acerto para 3 classes em diferentes rotações

<i>10 melhores GridSearch - 900rpm / Sinais Originais / 3 classes (Sigma: 0.3:0.5:2.8 / K: 50:50:300)</i>								
ID	RPM	Normalização	Sigma	K	Taxa de Acerto Média	Taxa de Acerto Mínima	Taxa de Acerto Máxima	Desvio Padrão da Taxa de Acerto
21	900	[0,1]	1,8	150	0,9994	0,9500	1,0000	0,0051
<i>10 melhores GridSearch - 900rpm / Sinais após DFA / 3 classes (Sigma: 0.3:0.5:2.8 / K: 50:50:300)</i>								
ID	RPM	Normalização	Sigma	K	Taxa de Acerto Média	Taxa de Acerto Mínima	Taxa de Acerto Máxima	Desvio Padrão da Taxa de Acerto
1	900	[0,1]	0,3	50	0,9996	0,9875	1,0000	0,0021
<i>10 melhores GridSearch - 1200rpm / Sinais Originais / 3 classes (Sigma: 0.3:0.5:2.8 / K: 50:50:300)</i>								
ID	RPM	Normalização	Sigma	K	Taxa de Acerto Média	Taxa de Acerto Mínima	Taxa de Acerto Máxima	Desvio Padrão da Taxa de Acerto
42	1200	[0,1]	0,3	300	0,9784	0,9375	1,0000	0,0145
<i>10 melhores GridSearch - 1200rpm / Sinais após DFA / 3 classes (Sigma: 0.3:0.5:2.8 / K: 50:50:300)</i>								
ID	RPM	Normalização	Sigma	K	Taxa de Acerto Média	Taxa de Acerto Mínima	Taxa de Acerto Máxima	Desvio Padrão da Taxa de Acerto
43	1200	[0,1]	0,8	50	0,9931	0,9750	1,0000	0,0084
<i>10 melhores GridSearch - 1500rpm / Sinais Originais / 3 classes (Sigma: 0.3:0.5:2.8 / K: 50:50:300)</i>								
ID	RPM	Normalização	Sigma	K	Taxa de Acerto Média	Taxa de Acerto Mínima	Taxa de Acerto Máxima	Desvio Padrão da Taxa de Acerto
88	1500	[0,1]	1,3	200	0,9866	0,9500	1,0000	0,0125
<i>10 melhores GridSearch - 1500rpm / Sinais após DFA / 3 classes (Sigma: 0.3:0.5:2.8 / K: 50:50:300)</i>								
ID	RPM	Normalização	Sigma	K	Taxa de Acerto Média	Taxa de Acerto Mínima	Taxa de Acerto Máxima	Desvio Padrão da Taxa de Acerto
73	1500	[0,1]	0,3	50	0,9836	0,9500	1,0000	0,0124

Fonte: elaborada pelo autor

Tabela 6 – Taxa média de acerto para 7 classes em diferentes rotações

<i>10 melhores GridSearch - 900rpm / Sinais Originais / 7 classes (Sigma: 0.3:0.5:2.8 / K: 50:50:300)</i>								
ID	RPM	Normalização	Sigma	K	Taxa de Acerto Média	Taxa de Acerto Mínima	Taxa de Acerto Máxima	Desvio Padrão da Taxa de Acerto
5	900	[0,1]	0,3	250	0,9990	0,9875	1,0000	0,0034
<i>10 melhores GridSearch - 900rpm / Sinais após DFA / 7 classes (Sigma: 0.3:0.5:2.8 / K: 50:50:300)</i>								
ID	RPM	Normalização	Sigma	K	Taxa de Acerto Média	Taxa de Acerto Mínima	Taxa de Acerto Máxima	Desvio Padrão da Taxa de Acerto
3	900	[0,1]	0,3	150	0,9899	0,9625	1,0000	0,0098
<i>10 melhores GridSearch - 1200rpm / Sinais Originais / 7 classes (Sigma: 0.3:0.5:2.8 / K: 50:50:300)</i>								
ID	RPM	Normalização	Sigma	K	Taxa de Acerto Média	Taxa de Acerto Mínima	Taxa de Acerto Máxima	Desvio Padrão da Taxa de Acerto
41	1200	[0,1]	0,3	250	0,9674	0,9125	1,0000	0,0197
<i>10 melhores GridSearch - 1200rpm / Sinais após DFA / 7 classes (Sigma: 0.3:0.5:2.8 / K: 50:50:300)</i>								
ID	RPM	Normalização	Sigma	K	Taxa de Acerto Média	Taxa de Acerto Mínima	Taxa de Acerto Máxima	Desvio Padrão da Taxa de Acerto
57	1200	[0,1]	1,8	150	0,9816	0,9500	1,0000	0,0129
<i>10 melhores GridSearch - 1500rpm / Sinais Originais / 7 classes (Sigma: 0.3:0.5:2.8 / K: 50:50:300)</i>								
ID	RPM	Normalização	Sigma	K	Taxa de Acerto Média	Taxa de Acerto Mínima	Taxa de Acerto Máxima	Desvio Padrão da Taxa de Acerto
95	1500	[0,1]	1,8	250	0,9944	0,9750	1,0000	0,0080
<i>10 melhores GridSearch - 1500rpm / Sinais após DFA / 7 classes (Sigma: 0.3:0.5:2.8 / K: 50:50:300)</i>								
ID	RPM	Normalização	Sigma	K	Taxa de Acerto Média	Taxa de Acerto Mínima	Taxa de Acerto Máxima	Desvio Padrão da Taxa de Acerto
80	1500	[0,1]	0,8	100	0,9726	0,9375	1,0000	0,0177

Fonte: elaborada pelo autor

Conforme observado nas Tabelas 5 e 6, a coluna ID representa a identificação dos testes com melhores parâmetros para cada classe. A normalização e K foram definidos como mostrado anteriormente. As taxas médias de acerto foram os parâmetros observados para se obter o melhor teste (ID) para cada classe.

7 RESULTADOS E DISCUSSÃO

Nesta seção, serão expostos os resultados e discussões obtidos com o processamento e classificação dos sinais de vibração, considerando-se as várias condições de operação.

Inicialmente, o classificador foi testado com os sinais originais, sem uso de DFA. Após isso, utilizou-se a DFA e foi rodado o mesmo algoritmo no programa *MatLab*. Os resultados são mostrados nos tópicos deste capítulo.

7.1 Taxas de acerto para 3 e 7 classes de desbalanceamento (sinais originais)

Para cada rotação foram geradas duas tabelas, uma para 3 classes (CD1, CD2 e CN0_SP0), e outra para 7 classes (CD1 - 0,5 g, CD1 - 1,0 g, CD1 - 1,5 g, CD2 - 0,5 g, CD2 - 1,0 g, CD2 - 1,5 g e CN0_SP0).

Os resultados do classificador na etapa de teste para cada classe estão nas Tabelas 7 a 12, que contém um cruzamento dos valores de entrada esperados para as classes e os valores de saída.

Conforme mostrado na Tabela 7, o cruzamento da entrada das classes e de suas saídas formam a diagonal principal, para as classes CD1 (com uma pá com excesso de massa), CD2 (com duas pás com excesso de massa) e CN0_SP0 (sistema balanceado).

Tabela 7 - Matriz de confusão gerada de vetores de três classes em 900 rpm.

		Saída do classificador		
		CD1	CD2	CN0_SP0
Teste	CD1	99,83	0	0,17
	CD2	0	100	0
	CN0_SP0	0	0	100

Fonte: Elaborada pelo autor

Para 900 rpm, obteve-se valor máximo de acerto (100%) para a classe com duas pás com excesso de massa (CD2) e sistema totalmente balanceado (CN0_SP0). Já na classe com uma pá com excesso de massa (CD1), o erro é de apenas 0,17%, sendo que

99,83% corresponde ao acerto do classificador para essa classe. Isso significa que o algoritmo classificou 0,17% dos dados da classe CD1 como pertencentes à classe CN0_SP0.

Tabela 8 – Matriz de confusão gerada de vetores de sete classes em 900 rpm.

		Saída do Classificador						CN0_SP0
		CD1- 0,5 g	CD1- 1,0 g	CD1- 1,5 g	CD2- 0,5 g	CD2- 1,0 g	CD2- 1,5 g	
Teste	CD1 - 0,5 g	100	0	0	0	0	0	0
	CD1 - 1,0 g	0	100	0	0	0	0	0
	CD1 - 1,5 g	0	0	99,39	0	0	0,61	0
	CD2 - 0,5 g	0	0	0	100	0	0	0
	CD2 - 1,0 g	0	0	0	0	100	0	0
	CD2 - 1,5 g	0	0	0,2	0	0	99,8	0
	CN0_SP0	0	0	0	0	0	0	100

Fonte: elaborado pelo autor.

Já na Tabela 8, que apresenta os 7 tipos de classes para 900 rpm, apenas na terceira (99,39%) e sexta coluna (99,9%) os valores de acerto não foram máximos, indicando para essa velocidade de rotação, bons valores para os dois conjuntos de classes.

Tabela 9 - Matriz de confusão gerada de vetores de três classes em 1200 rpm.

		Saída do classificador		
		CD1	CD2	CN0_SP0
Teste	CD1	96,7	3,3	0
	CD2	0,56	99,44	0
	CN0_SP0	0	2,88	97,12

Fonte: Elaborada pelo autor

Para 1200 rpm, os valores para as classes CD1 (96,7%) e CN0_SP0 (97,12%) foram inferiores comparados à rotação anterior (900 rpm), sendo a segunda classe (CD2) a que obteve um melhor resultado (99,44%), conforme a Tabela 9.

É possível observar que o algoritmo de classificação não obteve resultado de acerto máximo para todas as classes, porém sua confusão foi de apenas uma classe para a saída do classificador.

Tabela 10 – Matriz de confusão gerada de vetores de sete classes em 1200 rpm.

Matriz de Confusão Média	Saída do Classificador						CN0_SP0
	CD1-0,5 g	CD1-1,0 g	CD1-1,5 g	CD2-0,5 g	CD2-1,0 g	CD2-1,5 g	
CD1 - 0,5 g	92,06	0	6,05	1,89	0	0	0
CD1 - 1,0 g	0	100	0	0	0	0	0
CD1 - 1,5 g	2,59	0	90,22	1,8	0	5,39	0
Teste CD2 - 0,5 g	0	0	0	100	0	0	0
CD2 - 1,0 g	0	0	0	0	99,8	0	0,2
CD2 - 1,5 g	0	0	3,18	0	0	96,82	0
CN0_SP0	0	0	0	0,2	2,27	0	97,53

Fonte: elaborado pelo autor.

Conforme observado da tabela de 3 classes, a matriz de confusão para 7 classes também obteve um resultado pior, com todas as classes apresentando valores inferiores ou iguais à 100%, comparado à rotação anterior (900 rpm). Porém valores máximos (100%) foram obtidos na segunda (CD1 - 1,0g) e na quarta coluna (CD2 - 0,5 g).

Para a classe CD1-1,5g o resultado foi o pior (90,22%), obtendo quase 10% de taxa de erro. Observa-se que a confusão foi dispersa em mais de uma classe, com o classificador obtendo resultado de saída para as classes CD1-0,5g, CD2-0,5g, CD2-1,5g, além de corretamente obter saída para a classe esperada, CD1-1,5g.

Tabela 11 - Matriz de confusão gerada de vetores de três classes em 1500 rpm.

Matriz de Confusão Média	Saída do classificador		
	CD1	CD2	CN0_SP0
CD1	99,21	0,53	0,26
Teste CD2	2,65	97,21	0,14
CN0_SP0	0	0	100

Fonte: Elaborada pelo autor

Na tabela de 3 classes para 1500 rpm, o valor máximo (100%) é obtido apenas na última classe (CN0_SP0), que é a balanceada. Para as outras classes os valores foram próximos de 100% de acerto.

Diferente das tabelas de 3 classes para as rotações de 900 e 1200 rpm, a Tabela 11 mostra que para as duas primeiras classes (CD1 e CD2), a saída do classificador se confundiu para mais de duas classes.

Tabela 12 – Matriz de confusão gerada de vetores de sete classes em 1500 rpm.

Matriz de Confusão Média	Saída do Classificador						
	CD1-0,5 g	CD1-1,0 g	CD1-1,5 g	CD2-0,5 g	CD2-1,0 g	CD2-1,5 g	CN0_SP0
CD1 - 0,5 g	99,8	0	0	0,1	0	0	0,1
CD1 - 1,0 g	0	100	0	0	0	0	0
CD1 - 1,5 g	0	0	99,9	0,1	0	0	0
Teste CD2 - 0,5 g	0	0	0	100	0	0	0
CD2 - 1,0 g	0	3,07	0	0	96,93	0	0
CD2 - 1,5 g	0	0	1,11	0	0	98,89	0
CN0_SP0	0	0	0	0	0	0	100

Fonte: elaborada pelo autor.

Já para 7 classes, os valores foram próximos do máximo, ficando apenas a quinta classe (CD2-1,0g) com um valor um pouco abaixo, comparado aos outros. Os valores máximos foram para a segunda (CD1-1,0g), quarta (CD2-0,5g) e última classe (CN0_SP0).

É possível observar também, que apesar da primeira classe (CD1-0,5) obter uma taxa de acerto de 99,8%, a matriz de confusão aponta como saída outras duas classes (CD1-1,5g e CN0_SP0).

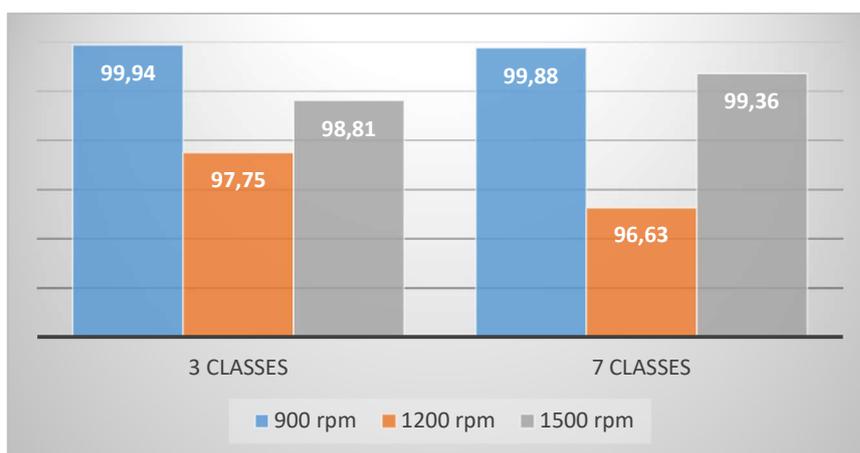
Para as tabelas com 3 classes, observa-se que os melhores resultados obtidos foram com a rotação de 900 rpm, com duas classes obtendo valores máximos, e uma média das três classes de 99,94%. Para 1200 rpm (a pior rotação para 3 classes), a taxa média de acerto foi 97,75%, e para 1500 rpm a taxa média de acerto foi de 98,81%.

O mesmo se repete para 7 classes, onde as melhores taxas de acerto se deram para 900 rpm, obtendo uma taxa média de acerto de 99,88%. Para 1200 rpm alguns valores destoam dos demais, mas mesmo assim não implicaram uma queda de mais de 10%. A taxa média de acerto para essa classe foi de 96,63%, sendo a pior média para 7 classes.

Para 1500 rpm, os valores foram próximos de 100%, e a taxa média de acerto foi de 99,36%.

Comparando-se os valores para 3 e 7 classes, observa-se que para 1200 rpm os valores médios das taxas de acerto foram os piores, e para 900 rpm foram obtidos os melhores resultados (99,94 e 99,88%), como mostrado no Gráfico 16.

Gráfico 16 – Comparação das taxas médias de acerto antes de DFA, de cada rotação, para 3 e 7 classes.



Fonte: Elaborado pelo autor.

Os valores melhores para 900 rpm podem ser explicados pelo nível de rotação ser menor e com isso gerar menos vibração no equipamento de captação de sinais, visto que os valores de sinais obtidos dependem de uma série de fatores como o ambiente controlado, e pequenas vibrações fora do sistema estudado podem gerar essas falhas.

7.2 Taxas de acerto para 3 e 7 classes (após DFA)

Para os sinais obtidos após o uso do método DFA, foram geradas matrizes para 3 e 7 classes. Os resultados do classificador na etapa de teste para cada classe estão nas Tabelas 13 a 18.

Tabela 13 - Matriz de confusão gerada de vetores de três classes em 900 rpm.

		Saída do classificador		
		CD1	CD2	CN0_SP0
Teste	CD1	99,97	0,03	0,00
	CD2	0,03	99,97	0,00
	CN0_SP0	0,00	0,05	99,95

Fonte: Elaborada pelo autor.

Para a rotação de 900 rpm é observado que não há um valor máximo de acerto (100%), porém, os erros são pequenos, com valores de 0,03% e 0,05%.

Tabela 14 – Matriz de confusão gerada de vetores de sete classes em 900 rpm.

Matriz de Confusão Média		Saída do Classificador						CN0_SP0
		CD1-0,5 g	CD1-1,0 g	CD1-1,5 g	CD2-0,5 g	CD2-1,0 g	CD2-1,5 g	
Teste	CD1 - 0,5 g	99,30	0,10	0,50	0,00	0,00	0,10	0,00
	CD1 - 1,0 g	0,60	97,61	01,29	0,00	0,00	0,50	0,00
	CD1 - 1,5 g	0,00	0,00	100,00	0,00	0,00	0,00	0,00
	CD2 - 0,5 g	0,20	0,10	0,09	97,91	01,30	0,10	0,30
	CD2 - 1,0 g	0,00	0,00	0,00	02,34	97,66	0,00	0,00
	CD2 - 1,5 g	0,11	0,11	0,32	0,11	0,00	99,36	0,00
	CN0_SP0	0,00	0,00	0,00	0,00	0,00	0,00	100,00

Fonte: Elaborada pelo autor.

Já para 7 classes, somente a terceira (CD1-1,5g) e a última coluna (CN0_SP0) conseguiram atingir 100% de acerto, enquanto todas as outras colunas diminuiram a taxa de acerto, não apresentando mais que 3% de taxa de erro.

No nível de rotação de 1200 rpm, com três classes, a Tabela 15 apresenta os resultados do classificador.

Tabela 15 - Matriz de confusão gerada de vetores de três classes em 1200 rpm.

		Saída do classificador		
		CD1	CD2	CN0_SP0
Teste	CD1	99,03	0,4	0,57
	CD2	0,07	99,93	0,00
	CN0_SP0	0,41	0,81	98,78

Fonte: Elaborada pelo autor.

Com apenas três classes, a taxa de acerto alcança valores próximos ao máximo de acerto (100%), porém nenhum deles atingindo 100%, e com valores próximos ao da matriz de confusão de três classes com rotação de 900 rpm.

Tabela 16 – Matriz de confusão gerada de vetores de sete classes em 1200 rpm.

		Saída do Classificador						CN0_SP0
		CD1- 0,5 g	CD1- 1,0 g	CD1- 1,5 g	CD2- 0,5 g	CD2- 1,0 g	CD2- 1,5 g	
Teste	Matriz de Confusão Média							
	CD1 - 0,5 g	96,80	0,83	0,72	0,31	0,31	0,00	01,03
	CD1 - 1,0 g	0,10	96,75	2,46	0,00	0,10	0,20	0,39
	CD1 - 1,5 g	0,33	1,49	96,48	0,32	0,21	0,53	0,64
	CD2 - 0,5 g	0,10	0,00	0,00	99,03	0,49	0,19	0,19
	CD2 - 1,0 g	0,00	0,00	0,00	0,00	100,00	0,00	0,00
	CD2 - 1,5 g	0,00	0,00	0,00	0,00	0,00	100,00	0,00
CN0_SP0	0,26	0,34	0,15	0,59	0,34	0,29	98,03	

Fonte: Elaborada pelo autor.

O teste com rotação de 1200 rpm apresenta valores diferentes daqueles gerados a 900 rpm. Na etapa de testes da Tabela 16, os resultados variaram, com as 3 primeiras classes (CD1-0,5g, CD1-1,0g e CD1-1,5g) apresentando resultados inferiores às demais, com mais de 3% de taxa de erro.

Se comparado à tabela com 3 classes, os resultados são piores de acordo com a média das classes (99,25% a 98,16%), pelo detalhamento obtido de um conjunto com mais classes.

A Tabela 17 mostra a matriz de confusão com três classes na rotação de 1500 rpm.

Tabela 17 - Matriz de confusão gerada de vetores de três classes em 1500 rpm.

		Saída do classificador		
		CD1	CD2	CN0_SP0
Teste	CD1	98,13	0,88	0,99
	CD2	2,27	97,46	0,27
	CN0_SP0	0,00	0,31	100

Fonte: Elaborada pelo autor.

Observa-se que os valores de teste com uma rotação de 1500 rpm tornaram-se menores para a primeira e segunda coluna, sendo a terceira coluna uma exceção. Isso pode ser explicado pelo aumento da rotação e maior variabilidade de desbalanceamento causado no sistema.

Já com o sistema balanceado, que é o caso da terceira coluna, o resultado foi máximo (100%), devido à falta de desbalanceamento.

Tabela 18 – Matriz de confusão gerada de vetores de sete classes em 1500 rpm.

Matriz de Confusão Média		Saída do Classificador						CN0_SP0
		CD1-0,5 g	CD1-1,0 g	CD1-1,5 g	CD2-0,5 g	CD2-1,0 g	CD2-1,5 g	
Teste	CD1 - 0,5 g	91,40	2,03	0,48	0,10	04,06	0,00	01,93
	CD1 - 1,0 g	0,32	99,15	0,21	0,00	0,21	0,00	0,11
	CD1 - 1,5 g	0,00	0,10	99,10	0,10	0,20	0,00	0,50
	CD2 - 0,5 g	0,41	0,68	0,58	92,59	3,70	0,19	1,85
	CD2 - 1,0 g	0,41	0,41	1,52	0,41	96,25	0,10	0,91
	CD2 - 1,5 g	0,00	0,00	0,00	0,00	0,00	100,00	0,00
	CN0_SP0	0,00	0,00	0,00	0,00	0,00	0,00	100,00

Fonte: Elaborada pelo autor.

O teste com rotação de 1500 rpm apresenta valores diferentes daqueles gerados a 900 rpm e 1200 rpm, com a primeira (CD1-0,5g) e quarta coluna (CD2-0,5g) apresentando um resultado muito destoante dos demais (mais que 7% de taxa de erro) e com a penúltima (CD2 - 1,5 g) e última coluna (CN0_SP0) apresentando resultados perfeitos.

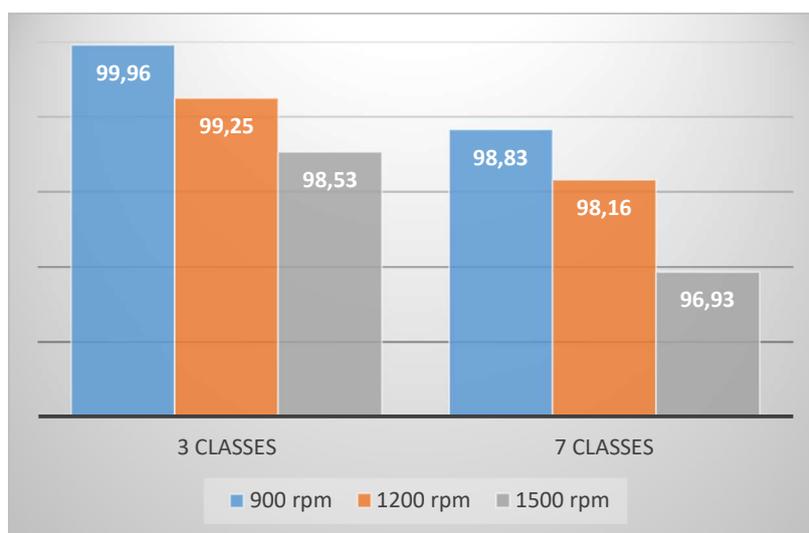
Os resultados obtidos para 3 classes após o uso de DFA, para 900 rpm, foram próximos de 100%, obtendo 99,96% de taxa média de acerto. Para 1200 rpm a taxa média

de acerto também foi próxima ao valor máximo, com 99,25% de taxa média de acerto. Para 1500 rpm (a pior das rotações), a taxa média de acerto foi de 98,53%.

Para as tabelas geradas com 7 classes após o uso de DFA, para 900 rpm, não houve uma grande disparidade de acertos da classe, obtendo uma taxa média de acerto de 98,83%. Para 1200 rpm, as taxas de acerto foram bem próximas às de 900 rpm, com uma taxa média de acerto de 98,16%. Para 1500 rpm (a pior das rotações), pelo fato de duas classes serem destoantes (CD1-0,5g e CD2-0,5g), a taxa média de acerto decaiu em relação às rotações anteriores, sendo de 96,93%.

Observa-se que para 3 e 7 classes, os valores são decrescentes conforme as rotações aumentam, conforme o Gráfico 17.

Gráfico 17 – Comparação das taxas médias de acerto pós DFA, de cada rotação, para 3 e 7 classes.



Fonte: Elaborada pelo autor.

Através do resultado da classificação com três classes, é fácil ter uma noção do tipo de defeito presente, mas não é possível identificar a severidade do problema, ou o quão desbalanceado o rotor está. Para se realizar uma manutenção preditiva, precisa-se acompanhar o nível da falha e o seu crescimento, até o momento adequado para parar o equipamento e realizar os devidos ajustes.

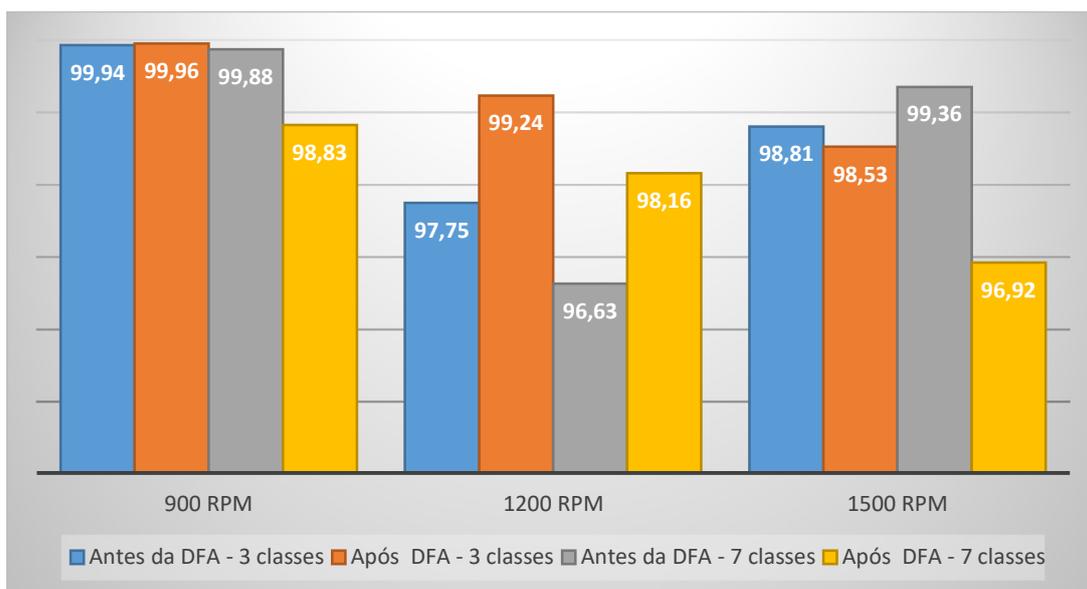
Observa-se nas tabelas que a taxa média de acerto com o maior valor se dá para o menor valor de rotação – 900 rpm, o que é explicado pelo fato de menores valores de rotações produzirem menores momentos angulares, logo, menores desbalanceamentos

ao longo das medições. Sendo assim os valores obtidos ao longo da medição são mais confiáveis e próximos uns aos outros.

Além disso, observa-se o fato de que o uso da classificação por meio de rede neural de base radial se mostra um bom método. O fato se explica ao observar os desvios padrões da taxa de acerto nas Tabelas 4 e 5 de *GridSearch*. Os valores se mostraram muito pequenos, não chegando a 0,03, o que mostra a confiabilidade do método em classificar os dados.

Em relação ao uso da DFA, resultados diferentes foram obtidos a partir de parâmetros diferentes, como rotação e conjunto de classes. Para 3 classes, a taxa média de acerto foi melhor para os valores após a DFA, para todas as rotações. Já para 7 classes, somente na rotação de 1200 rpm a taxa foi melhor para os valores após a DFA, ficando a rotação de 900 rpm distantes apenas por 0,01%. O Gráfico 18 ilustra a comparação.

Gráfico 18 – Comparação de resultados antes e após a utilização do método DFA.



Fonte: Elaborada pelo autor.

Esse resultado indica que a análise de DFA causa mais impacto para um conjunto de classes que possui menos acurácia. Isso pode ser explicado pelo fato de valores de sinais muito destoantes serem obtidos e entrarem no campo de estudo do DFA, mudando o resultado final e levando o resultado para uma menor acurácia.

Por fim, para obter o estudo preditivo através desse método, é necessária a criação de uma base de dados de maior tamanho, a fim de servir de comparação para

dados obtidos em situações reais de funcionamento de aerogeradores, para quando for o momento, realizar a manutenção do equipamento já com o conhecimento do problema enfrentado.

Em relação aos resultados obtidos por Melo Junior (2019), observa-se uma certa proximidade entre os resultados obtidos utilizando os métodos utilizados (Gaussiano, KLT e Redes Neurais) por ele e pelo método da presente dissertação (RBFN).

Para 900 rpm, a média geral dos testes das 7 classes foi de 99,31% para o método Gaussiano, 99,88% para Karhunen-Loève e 98,67% para redes neurais. Enquanto no presente trabalho a média foi de 98,83%. Para 1200 rpm, a média geral foi de 93,41%, 94,91% e 93,99%, respectivamente. Enquanto no presente trabalho a média foi de 98,15%. E para 1500 rpm, a média geral foi de 98,59%, 97,79% e 97,37%, respectivamente. Enquanto no presente trabalho a média foi de 96,92%. A Tabela 19 mostra a comparação de valores médios entre os métodos.

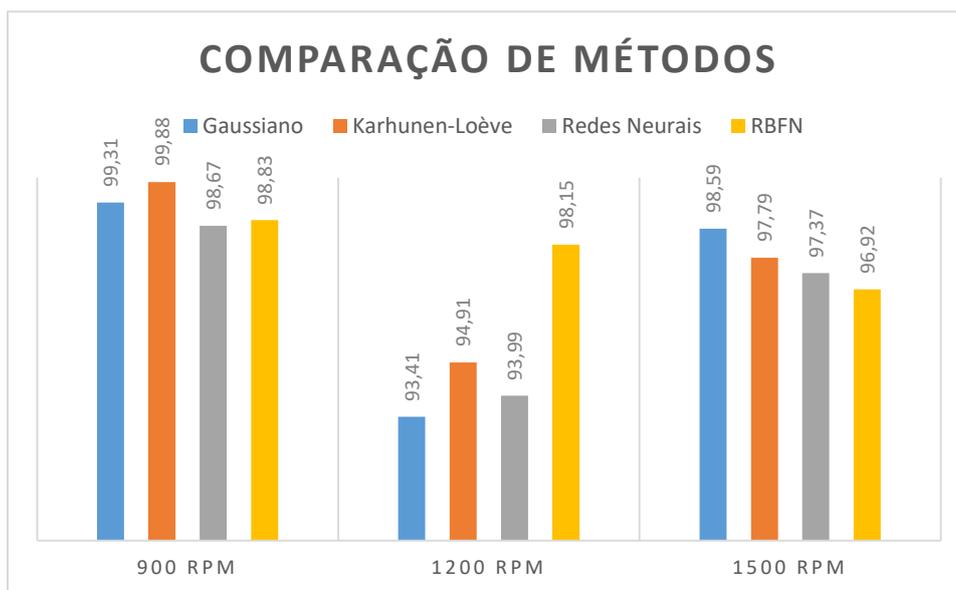
Tabela 19 - Comparação de valores médios da taxa de acerto para diferentes métodos para as 3 rotações de trabalho.

	Gaussiano	Karhunen-Loève	Redes Neurais	RBFN
900 RPM	99,31	99,88	98,67	98,83
1200 RPM	93,41	94,91	93,99	98,15
1500 RPM	98,59	97,79	97,37	96,92

Fonte: Elaborada pelo autor.

Para ilustrar a Tabela 19, foi plotado o Gráfico 19 para comparação visual dos valores.

Gráfico 19 – Comparação de resultados de classificadores.



Fonte: elaborada pelo autor.

Observa-se que ambos os métodos têm suas vantagens e desvantagens a partir de diferentes tipos de situações. Esse fato permite a compreensão de que todos os métodos podem ser usados em combinação uns com os outros, a fim de permitir um melhor resultado final.

8 CONCLUSÃO

Os sinais de vibração coletados foram pré-processados pela DFA e a classificação dos sinais foi realizada pela técnica rede neural de base radial. O primeiro processamento foi realizado com o intuito de verificar o balanceamento do sistema e das pás, o que foi confirmado pela classificação com 100% de acertos da classe balanceada, garantindo a possibilidade de utilização do sistema para ensaios de vibração.

Os testes foram realizados utilizando três velocidades de rotação diferentes: 900, 1200 e 1500 rpm, com a primeira apresentando um resultado mais confiável devido à baixa velocidade de rotação. Os dados foram divididos em dois conjuntos de classes: 3 e 7. A primeira tinha como objetivo testar o classificador para uma situação de desbalanceamento em uma pá, desbalanceamento em duas pás, e pás balanceadas. A segunda tinha por objetivo uma classificação mais apurada, com pesos diferentes sendo adicionados às pás.

Os melhores parâmetros foram escolhidos através de *GridSearch* para os testes feitos com as três rotações, e para os diferentes tipos de classes. Os valores de K e Σ foram escolhidos através desse método e utilizados para encontrar a melhor taxa média de acerto do classificador.

Foi observado que para a classificação antes do uso do método DFA, a rotação de 900 rpm apresentou os melhores resultados, tanto para 3, quanto para 7 classes, com resultados quase perfeitos (100%). Por outro lado, a rotação de 1200 rpm apresentou os piores resultados comparados às outras, principalmente no conjunto de 7 classes.

Para os dados classificados após o uso da DFA, a rotação de 900 rpm continuou apresentando as melhores taxas de acerto. Entretanto, diferente do caso anterior, a rotação de 1500 rpm apresentou as piores taxas médias de acerto.

Apesar de todos os erros de classificação encontrados nas três rotações testadas, a classe balanceada sempre obteve altos índices de acertos (99,58% para três classes e 99,34% para sete classes, em média), mostrando que o classificador é capaz de diferenciar a condição normal de funcionamento daquelas com alguma anormalidade presente.

Ademais, na maioria dos casos, os diferentes níveis de desbalanceamentos foram diferenciados com alta precisão (todas acima de 90%), fazendo dessa metodologia uma poderosa ferramenta para uso em manutenções preditivas.

Comparando-se com métodos usados em trabalhos passados, a RBFN apresentou uma diferença positiva significativa para a rotação de 1200 rpm, destacando-se das demais (Método Gaussiano, KLL e Redes Neurais).

De um modo geral, os resultados obtidos são muito promissores e podem dar contribuições relevantes no desenvolvimento de um sistema de detecção e classificação de defeitos em pás de aerogeradores.

REFERÊNCIAS

- ALKMIM, Mansour H.; FABRO, Adriano T.; DE MORAIS, Marcus V. G. *Optimization of a tuned liquid column damper subject to an arbitrary stochastic wind. Journal of the Brazilian Society of Mechanical Sciences and Engineering*, vol. 40, nº 11, nov. 2018.
- ALMEIDA, T. M. *Projeto e fabricação de uma bancada de testes para protótipos de pás de rotores eólicos*. 2013. 33f. Trabalho de Conclusão de Curso (Graduação em Engenharia Mecânica) - Departamento de Engenharia Mecânica e de Produção, Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2013.
- ALVARENGA JÚNIOR, Wagner José de. *Métodos de otimização hiperparamétrica: um estudo comparativo utilizando árvores de decisão e florestas aleatórias na classificação binária*, 2018.
- ALVIM FILHO, A. de C.; *Aspectos Tecnológicos das Fontes Alternativas de Energia. (Energia Eólica)*, [S.l.]. 2009. Disponível em: <http://docplayer.com.br/3014195-Aspectos-tecnologicos-das-fontes-de-energia-renovaveis-energia-eolica.html>. Acesso em abr. 2009.
- B. FITZGERALD, B. Basu, *Cable connected active tuned mass dampers for control of in-plane vibrations of wind turbine blades*, J. Sound Vib. 333 (23) (2014) 5980e6004.
- BEN-DAYA MS, DUFFUAA AR. *Handbook of maintenance management and engineering*. Springer Verlag London Limited; 2009.
- BERGSTRA, James; BENGIO, Yoshua. *Random search for hyper-parameter optimization*. Journal of Machine Learning Research, v. 13, n. Feb, p. 281-305, 2012.
- BETZ A. (D. G. Randall, Trans), *Introduction to the Theory of Flow Machines*, 1966.
- BRAGA, F. *Uso de redes neurais de funções de base radial e regressão linear múltipla para a previsão de propriedades mecânicas de vergalhões de aço*. 2019.

BP WIND POWER STATISTICS 2018 [Online]. Disponível em: <https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/xlsx/energy-economics/statistical-review/bp-stats-review-2019-all-data.xlsx> (2019). Acessado em 22 de julho de 2021.

BURTON, T., SHARPE, D. *Wind Energy Handbook*. John Wiley and Son, LTD. 2001.

C.K. PENG, S.V. BULDYREV, S. HAVLIN, M. SIMONS, H.E. STANLEY, A.L. *Goldberger Mosaic organization of DNA nucleotides*. Phys Rev E, 49 (1994), pp. 1685-1689.

CHANDRASEKHAR, Kartik; STEVANOVIC, Nevena; CROSS, Elizabeth J.; DERVILIS, Nikolaos; WORDEN, Keith. *Damage detection in operational wind turbine blades using a new approach based on machine learning*. Renewable Energy, vol. 168, p. 1249–1264, maio 2021

CHEN, Wanqiu; QIU, Yingning; FENG, Yanhui; LI, Ye; KUSIAK, Andrew. *Diagnosis of wind turbine faults with transfer learning algorithms*. Renewable Energy, vol. 163, p. 2053–2067, jan. 2021.

CHEN, Hansi; LIU, Hang; CHU, Xuening; LIU, Qingxiu; XUE, Deyi. *Anomaly detection and critical SCADA parameters identification for wind turbines based on LSTM-AE neural network*. Renewable Energy, vol. 172, p. 829–840, jul. 2021.

CHO, Seongpil; CHOI, Minjoo; GAO, Zhen; MOAN, Torgeir. *Fault detection and diagnosis of a blade pitch system in a floating wind turbine based on Kalman filters and artificial neural networks*. Renewable Energy, vol. 169, p. 1–13, maio 2021.

CRESESB - Centro de Referência para Energia Solar e Eólica Sérgio Brito. *Tipos de Aerogeradores para Geração de Energia Elétrica*. <http://www.cresesb.cepel.br>, 2008. Disponível em: http://www.cresesb.cepel.br/index.php?section=com_content&lang=pt&cid=231 <>. Acesso em: 14, maio de 2021.

DA COSTA, Cesar; MATHIAS, Mauro Hugo; RAMOS, Pedro; GIRAO, Pedro Silva. *A new approach for real time fault diagnosis in induction motors based on vibration measurement*. In: 2010 IEEE INSTRUMENTATION & MEASUREMENT TECHNOLOGY CONFERENCE PROCEEDINGS, maio 2010.

DE AZEVEDO, Henrique Dias Machado; ARAÚJO, Alex Maurício; BOUCHONNEAU, Nadège. *A review of wind turbine bearing condition monitoring: State of the art and challenges*. Renewable and Sustainable Energy Reviews, vol. 56, p. 368–379, abr. 2016.

DE MOURA, Elineudo Pinho; DE ABREU MELO JUNIOR, Francisco Erivan; ROCHA DAMASCENO, Filipe Francisco; CAMPOS FIGUEIREDO, Luis Câmara; DE ANDRADE, Carla Freitas; DE ALMEIDA, Maurício Soares; ALEXANDRE COSTA ROCHA, Paulo. *Classification of imbalance levels in a scaled wind turbine through detrended fluctuation analysis of vibration signals*. Renewable Energy, vol. 96, p. 993–1002, out. 2016.

DE NOVAES PIRES LEITE, Gustavo; DA CUNHA, Guilherme Tenório Maciel; DOS SANTOS JUNIOR, José Guilhermino; ARAÚJO, Alex Maurício; ROSAS, Pedro André Carvalho; STOSIC, Tatijana; STOSIC, Borko; ROSSO, Osvaldo Anibal. *Alternative fault detection and diagnostic using information theory quantifiers based on vibration time-waveforms from condition monitoring systems: Application to operational wind turbines*. Renewable Energy, vol. 164, p. 1183–1194, fev. 2021.

DU, Ying; ZHOU, Shengxi; JING, Xingjian; PENG, Yeping; WU, Hongkun; KWOK, Ngaiming. *Damage detection techniques for wind turbine blades: A review*. Mechanical Systems and Signal Processing, vol. 141, p. 106445, jul. 2020.

FENG, Hsuan-Ming; CHOU, Hsiang-Chai. *Evolutional RBFNs prediction systems generation in the applications of financial time series data*. Expert Systems with Applications, v. 38, n. 7, p. 8285-8292, 2011.

FREITAS, R. M. DE; Genovez, P. C.; Bentz, M. C.; Rosa, R. R.; Shimabukuro, Y. E. *Análise de anisotropia de imagens utilizando o método DFA : um estudo de caso na área de exploração de petróleo*. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto

Sensoriamento. Anais...2009

GARCÍA MÁRQUEZ, Fausto Pedro; TOBIAS, Andrew Mark; PINAR PÉREZ, Jesús María; PAPAELIAS, Mayorkinos. *Condition monitoring of wind turbines: Techniques and methods*. Renewable Energy, vol. 46, p. 169–178, out. 2012.

GOMEZ, Luis A. G.; LOURENCO, Luis F. N.; GRILO, Ahda P.; SALLES, M. B. C.; MEEGAHAPOLA, Lasantha; FILHO, A. J. Sguarezi. *Primary Frequency Response of Microgrid Using Doubly Fed Induction Generator With Finite Control Set Model Predictive Control Plus Droop Control and Storage System*. IEEE Access, vol. 8, p. 189298–189312, 2020.

HAMEED Z, HONG YS, CHOA YM, AHN SH, Song CK. *Condition monitoring and fault detection of wind turbines and related algorithms: a review*. Renewable and Sustainable Energy Reviews 2009;13:1e39.

HARDSTONE, Richard; POIL, Simon-Shlomo; SCHIAVONE, Giuseppina; JANSEN, Rick; NIKULIN, Vadim V.; MANSVELDER, Huibert D.; LINKENKAER-HANSEN, Klaus. *Detrended Fluctuation Analysis: A Scale-Free View on Neuronal Oscillations*. Frontiers in Physiology, vol. 3, 2012.

HAU, E. *Wind Turbines - Fundamentals, Technologies, Application, Economics*. 2. ed. Springer, 2006.

HAYKIN, Simon. *Neural Networks and Learning Machines*. 3 ed, p. 1-263, New York: Prentice Hall, 2009.

HÜBNER, G.R.; PINHEIRO, H.; DE SOUZA, C.E.; FRANCHI, C.M.; DA ROSA, L.D.; DIAS, J.P. *Detection of mass imbalance in the rotor of wind turbines using Support Vector Machine*. Renewable Energy, vol. 170, p. 49–59, jun. 2021.

JAMES, Gareth; WITTEN, Daniela; HASTIE, Trevor; TIBSHIRANI, Robert. *An Introduction to Statistical Learning*. [S. l.]: Springer New York, 2013.

JORDAN, M. I.; MITCHELL, T. M. *Machine learning: Trends, perspectives, and prospects*. *Science*, vol. 349, n° 6245, p. 255–260, 16 jul. 2015.

KHALFALLAH, M. G.; KOLIUB, A. M. *Effect of dust on the performance of wind turbines*. *Desalination*, 209-220, 2007.

KHOSRAVI, A.; KOURY, R.N.N.; MACHADO, L.; PABON, J.J.G. *Prediction of wind speed and wind direction using artificial neural network, support vector regression and adaptive neuro-fuzzy inference system*. *Sustainable Energy Technologies and Assessments*, vol. 25, p. 146–160, fev. 2018.

KNEZEVIC J. *Reliability, maintainability and supportability engineering: a probabilistic approach*. McGraw Hill; 1993.

KRIESEL, David. *A brief introduction on neural networks*. 2007.

LIU, Zhenqing; WANG, Yize; HUA, Xugang; ZHU, Hongping; ZHU, Zhiwen. *Optimization of wind turbine TMD under real wind distribution countering wake effects using GPU acceleration and machine learning technologies*. *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 208, p. 104436, jan. 2021.

LOPES, A., *Produção eólica e enquadramento técnico económico em Portugal*. FEUP (Faculdade de Engenharia do Porto), 2009.

LYDIA, M.; EDWIN PREMKUMAR, G. *Machine learning applications in wind turbine generating systems*. *Materials Today: Proceedings*, dez. 2020.

MELO JUNIOR, Francisco Erivan de Abreu; DE MOURA, Elineudo Pinho; COSTA ROCHA, Paulo Alexandre; DE ANDRADE, Carla Freitas. *Unbalance evaluation of a scaled wind turbine under different rotational regimes via detrended fluctuation analysis of vibration signals combined with pattern recognition techniques*. *Energy*, vol. 171, p. 556–565, mar. 2019.

MISHNAEVSKY, L., Jr. *Repair of wind turbine blades: Review of methods and related*

computational mechanics problems. Renewable Energy, v. 140, p. 828–839, set. 2019.

MOVSESSIAN, Artur; GARCÍA CAVA, David; TCHERNIAK, Dmitri. *An artificial neural network methodology for damage detection: Demonstration on an operating wind turbine blade*. Mechanical Systems and Signal Processing, vol. 159, p. 107766, out. 2021.

NARAYAN, Yogendra. *Direct comparison of SVM and LR classifier for SEMG signal classification using TFD features*. Materials Today: Proceedings, fev. 2021

NEW ICE AGE BEGINS: Ice Chunks Thrown from Wind Turbines Threaten Lives, Smashing Buildings and Passing Trucks. Stopthesethings.com, 2018. Disponível em: <<https://stopthesethings.files.wordpress.com/2018/03/ice-covered-blade.jpg>>. Acesso em: 14, maio de 2021.

NGUYEN, Thuy T.T.; ARMITAGE, Grenville. *A survey of techniques for internet traffic classification using machine learning*. IEEE Communications Surveys & Tutorials, vol. 10, nº 4, p. 56–76, 2008.

PARMAR, J. G. *et al.* *Prediction of end milling process parameters using artificial neural network*. Materials Today: Proceedings, out. 2020.

PARK, J.-H.; PARK, H.-Y.; JEONG, S.-Y.; LEE, S.-I.; SHIN, Y.-H.; PARK, J.-P. *Linear vibration analysis of rotation wind-turbine blade*. Current Applied Physics, S332-S334, 2010.

PAVLOV, A. N. *et al.* *Extended detrended fluctuation analysis of sound-induced changes in brain electrical activity*. Chaos, Solitons & Fractals, v. 139, p. 109989, out. 2020.

PENG, C. -K. *Quantification of Scaling Exponents and Crossover Phenomena in Nonstationary Heartbeat Time Series*. Chaos: An Interdisciplinary Journal of Nonlinear Science, vol. 5, no 1, março de 1995, p. 82–87.

PENG, C. K.; BULDYREV, S. V.; HAVLIN, S.; SIMONS, M.; STANLEY, H. E.; RAO, S. *Vibrações Mecânicas*. 4. ed. São Paulo: Pearson Prentice Hall, 2009.

PONCI, Luciano Paiva; CRECI, Geraldo; MENEZES, João Carlos. *Simplified procedure for vibration analysis and dynamic balancing in mechanical systems with beats frequency*. Measurement, vol. 174, p. 109056, abr. 2021.

RAHMANN, C.; JARA, J.; SALLES, M. B. C. *Effects of inertia emulation in modern wind parks on isolated power systems*. In: 2015 IEEE POWER & ENERGY SOCIETY GENERAL MEETING, jul. 2015.

RAUBER, Thomas Walter. *Redes neurais artificiais*. Universidade Federal do Espírito Santo, 2005.

SAGOL, E.; REGGIO, M.; ILINCA, A. *Issues concerning roughness on wind turbine blades*. Renewable and Sustainable Energy Reviews, 514-525, 2013.

SAREEN, A.; SAPRE, C. A.; SELIG, M. S. *Effects of leading edge erosion on wind turbine blade performance*. Wind Energy, 1531-1542, 2014.

SCHWENKER, Friedhelm; KESTLER, Hans A.; PALM, Günther. *Three learning phases for radial-basis-function networks*. Neural Networks, v. 14, n. 4-5, p. 439-458, 2001.

SOLTANI, M. R.; BIRJANDI, A. H.; MOORANI, M. S. *Effect of surface contamination on the performance of a section of a wind turbine blade*. Scientia Iranica, 349-357, 2011.

SQUIRE, Larry *et al.* (Ed.). *Fundamental neuroscience*. Academic Press, 2012.

STAINO, A.; BASU, B.; NIELSEN, S. R. *Actuador control of edgewise vibrations in wind turbine blades*. Journal of Sound and Vibration, 1233-1256, 2012.

TANDON N, NAKRA BC. *Vibration and acoustic monitoring techniques for the detection of defects in rolling element bearings e a review*. Shock and Vibration Digest 1992;24(3):3e11

VON ZUBEN, IA353–Profs Fernando J.; ATTUX, Romis RF. *Redes Neurais com Funções de Ativação de Base Radial*. DCA/FEEC/Unicamp, 2001.

XU, Jiaohui; TAN, Wen; LI, Tingshun. *Predicting fan blade icing by using particle swarm optimization and support vector machine algorithm*. Computers & Electrical Engineering, vol. 87, p. 106751, out. 2020.

YOKOYAMA, S. *Lightning protection of wind turbine blades*. Electric Power Systems Research, 3-9, 2013.

ZARE, Samira; AYATI, Moosa. *Simultaneous fault diagnosis of wind turbine using multichannel convolutional neural networks*. ISA Transactions, vol. 108, p. 230–239, fev. 2021.

ZHAO, Yan; PAN, Jianing; HUANG, Zhuye; MIAO, Yachao; JIANG, Jianqun; WANG, Zhenyu. *Analysis of vibration monitoring data of an onshore wind turbine under different operational conditions*. Engineering Structures, vol. 205, p. 110071, fev. 2020.

ZHAO, Shili; ZHANG, Song; LIU, Jincun; WANG, He; ZHU, Jia; LI, Daoliang; ZHAO, Ran. *Application of machine learning in intelligent fish aquaculture: A review*. Aquaculture, vol. 540, p. 736724, jul. 2021.

ZHOU, Yang; CHEN, Chaoyang; CHENG, Mark; ALSHAHRANI, Yousef; FRANOVIC, Sreten; LAU, Emily; XU, Guanghua; NI, Guoxin; CAVANAUGH, John M.; MUH, Stephanie; LEMOS, Stephen. *Comparison of machine learning methods in sEMG signal processing for shoulder motion recognition*. Biomedical Signal Processing and Control, vol. 68, p. 102577, jul. 2021.